

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**AVALIAÇÃO DE TÉCNICAS BASEADAS EM ANÁLISE
EXTERNA PARA DETECÇÃO DE FALHAS EM PROCESSOS
INDUSTRIAIS OPERANDO EM MÚLTIPLOS MODOS**

DISSERTAÇÃO DE MESTRADO

ARTHUR ALMEIDA ASSIS

VITÓRIA

2018

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**AVALIAÇÃO DE TÉCNICAS BASEADAS EM ANÁLISE
EXTERNA PARA DETECÇÃO DE FALHAS EM PROCESSOS
INDUSTRIAIS OPERANDO EM MÚLTIPLOS MODOS**

ARTHUR ALMEIDA ASSIS

Dissertação de Mestrado apresentada como
requisito parcial para obtenção do título de
Mestre em Engenharia Elétrica.

Orientador:
Prof. Dr. Celso José Munaro.

VITÓRIA

2018

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)

A848a Assis, Arthur Almeida, 1991-
Avaliação de técnicas baseadas em análise externa para
detecção de falhas em processos industriais operando em
múltiplos modos / Arthur Almeida Assis. – 2018.
67 f. : il.

Orientador: Celso José Munaro.
Dissertação (Mestrado em Engenharia Elétrica) –
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Controle de processo. 2. Modelos de engenharia.
3. Localização de falhas (Engenharia). 4. Controle (Engenharia).
5. Processos industriais. I. Munaro, Celso José. II. Universidade
Federal do Espírito Santo. Centro Tecnológico. III. Título.

CDU: 621.3

ARTHUR ALMEIDA ASSIS

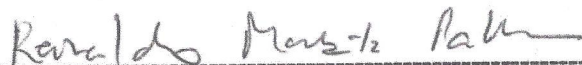
**AVALIAÇÃO DE TÉCNICAS BASEADAS EM ANÁLISE
EXTERNA PARA DETECÇÃO DE FALHAS EM PROCESSOS
INDUSTRIAIS OPERANDO EM MÚLTIPLOS MODOS**

Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica.

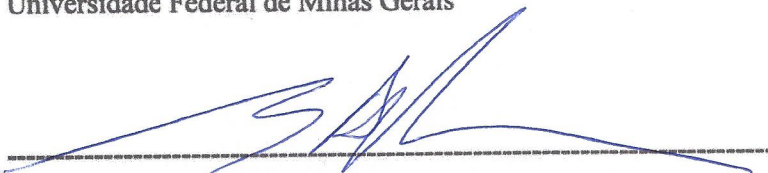
COMISSÃO EXAMINADORA



Prof. Dr. Celso José Munaro
Universidade Federal do Espírito Santo
Orientador



Prof. Dr. Reinaldo Martinez Palhares
Universidade Federal de Minas Gerais



Prof. Dr. Luiz Affonso Henderson Guedes de Oliveira
Universidade Federal do Rio Grande do Norte

“Inteligência é a capacidade de se adaptar à mudança”

Stephen Hawking

Agradecimentos

Agradeço aos meu pais e familiares pelo incentivo em seguir no caminho escolhido. A minha namorada Talita Colombi, por todo apoio e carinho, não me deixando duvidar da minha capacidade durante os momentos de dificuldade. Aos amigos do laboratório LCI, Gustavo Boina Santi, Débora Martins, Marcos Vinicius Cypriano, Felipe Lobo, Vinicius Belmuds, Óscar Becerra, Diego Calegário, Heitor Guzzo, entre outros, pelos momentos de descontração, foco nas horas necessárias e também de iluminação relacionadas a pesquisa. Ao meu orientador Dr. Celso José Munaro por todo direcionamento, ensinando a fazer as perguntas certas. A FAPES e VALE S.A. pelo apoio e financiamento desta pesquisa. Além disso, também agradecer a todos os amigos que fizeram parte desta caminhada, ajudando da maneira que podiam. E por fim, deixo meu agradecimento ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da UFES por todo suporte e estrutura fornecidos.

RESUMO

Com o passar dos anos, os processos industriais vêm se tornando cada vez mais complexos e mais instrumentados. O monitoramento adequado de diversos sinais simultaneamente é um desafio, ainda maior quando suas condições operacionais são frequentemente alteradas. Neste contexto, é necessária utilização de técnicas que consigam realizar o monitoramento multivariado do processo nas suas mais diversas condições operacionais. Este trabalho apresenta um estudo sobre as técnicas clássicas de monitoramento multivariado, tais como os métodos PCA e PLS, além de técnicas que utilizam modelos para explicar o comportamento do processo, entrando neste quesito a análise externa que trata as diversas condições operacionais do processo. Foram desenvolvidos três estudos de caso: o primeiro utilizando o simulador CSTR, e o segundo e o terceiro utilizando dados de um ventilador industrial. Nas situações aqui propostas, a metodologia conseguiu detectar falhas, independente da condição operacional do processo.

ABSTRACT

Over the years, industrial processes have become increasingly complex and more instrumented. The proper monitoring of multiple signals simultaneously is challenge, even more when their operation conditions often changes. In this context, it is necessary to use techniques and methods that can realize the process monitoring in its most diverse conditions. This work presents a study about classic techniques of multivariate process control, such as PCA and PLS, as well techniques that use models to explain the process behavior. To address the multiple modes question, the external analysis is used, to explain the changes in the process operational conditions. Three case studies were developed: the first using the CSTR simulator, the second and third use industrial data from an industrial fan. In the situations analyzed in the case studies, the methodology was able to achieve a correct fault detection, regardless of the process operational condition.

LISTA DE FIGURAS

Figura 1 – Métodos de controle de processos com base no tipo de conhecimento	11
Figura 2 – Ilustração da carta de controle de Shewhart. Os pontos são observações.....	16
Figura 3 – Monitoramento univariado em comparação com o multivariado	18
Figura 4 – Classificação dos métodos baseados no histórico do processo	22
Figura 5 – Esquema geral para detecção e diagnóstico de falhas baseados em modelos	25
Figura 6 – Descrição da análise externa	27
Figura 7 – Esquemático do processo CSTR	33
Figura 8 – Ventilador industrial (a) pás axiais e (b) com pás radiais	37
Figura 9 – Curvas Características para diferentes configurações das pás no rotor (a) Centrifugo com pás inclinadas para trás (b) centrifugo com pás inclinadas para frente (c) axial propulsor e (d) tubo axial.....	38
Figura 10 - Efeito da densidade sobre as curvas características do ventilador.....	40
Figura 11 - Relação entre o <i>setpoint</i> de temperatura e o sinal de controle de resfriamento	43
Figura 12 - Variações nos <i>setpoints</i> de nível e temperatura para treinamento e o comportamento dos sinais de temperatura de nível do reator	44
Figura 13 - Norma dos resíduos das variáveis 8, 13 e 14 para os diferentes tipos de modelos testados.....	45
Figura 14 - Resultados mais representativos da tabela 4.....	46
Figura 15 - Sinal de rotação do ventilador para o período estudado	48
Figura 16 - Sinais de vibração do ventilador para o período estudado.....	48
Figura 17 - Seleção de dados para treinamento	49
Figura 18 - Normas dos resíduos de cada modelo em cada etapa do treinamento	51
Figura 19 - Estatísticas de monitoramento para cada modelo de análise externa	52
Figura 20 - Curvas características do ventilador	55
Figura 21 - Curvas características em ambiente computacional	56
Figura 22 – Diagrama para obtenção do resíduo de potência.....	56
Figura 23 – Sinal de potência medido, estimado e o resíduo resultante.....	57
Figura 24 – Diagrama atualizado com a temperatura do ar de serviço do ventilador	58
Figura 25 – Potência estimada corrigida com a densidade.....	58
Figura 26 - Resíduo da potência com os limiares de controle.....	59
Figura 27 - Sinais de rotação e diferença de pressão.....	60
Figura 28 - Estatística T^2 para as variáveis de rotação, diferença de pressão e temperatura do ar de serviço do ventilador	61
Figura 29 – Potência estimada e resíduos para dados de Jan/18	62

LISTA DE TABELAS

Tabela 1 – Variáveis do processo CSTR	35
Tabela 2 – Falhas possíveis no simulador	35
Tabela 3 – Sinais utilizados nas aplicações do ventilador	41
Tabela 4 – Resultados Simulação de Falhas CSTR	46
Tabela 5 – Média e desvio padrão para a vibração do lado acoplado	50
Tabela 6 – Média e desvio padrão para a vibração do lado não acoplado	50
Tabela 7 – Métricas medidas na aplicação	53

Sumário

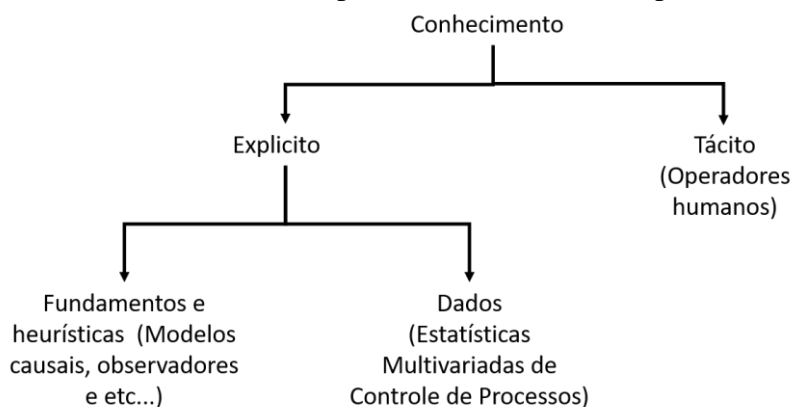
1	INTRODUÇÃO	11
2	REVISÃO DA LITERATURA.....	15
2.1	ANÁLISE UNIVARIADA.....	15
2.2	ANÁLISE MULTIVARIADA	18
2.2.1	PCA	19
2.2.2	PLS	20
2.2.3	ICA	21
2.3	DETECÇÃO DE FALHAS BASEADO EM DADOS – MÉTODO PCA.....	21
2.4	DETECÇÃO DE FALHAS BASEADO EM MODELOS	24
2.5	ANÁLISE EXTERNA.....	27
2.6	METODOLOGIA	30
3	ESTUDOS DE CASO	33
3.1	CSTR	33
3.1.1	Descrição do Processo	33
3.2	VENTILADOR INDUSTRIAL.....	36
4	APLICAÇÃO E DISCUSSÃO DOS RESULTADOS	42
4.1	APLICAÇÃO AO CSTR.....	42
4.2	MONITORAMENTO DA VIBRAÇÃO DE UM VENTILADOR INDUSTRIAL	47
4.3	APLICAÇÃO PARA O MONITORAMENTO DE EFICIÊNCIA DO VENTILADOR.....	54
5	CONCLUSÃO	63
	REFERÊNCIAS BIBLIOGRÁFICAS	65

1 INTRODUÇÃO

Os avanços tecnológicos nos anos recentes têm resultado em um aumento do número de processos industriais complexos, fazendo com que seja um desafio realizar o controle e o gerenciamento desses processos para que se obtenha um produto final de qualidade (ALDRICH; AURET, 2013). Esse aumento de complexidade também vem com um aumento da instrumentação das plantas, gerando uma quantidade enorme de dados a serem monitorados para que a qualidade do processo seja assegurada, evitando a ocorrência de falhas ou comportamentos anômalos.

O monitoramento dessa grande base de dados, do ponto de vista de detecção de falhas, é feito através de modelos que consigam explicar o processo. O comportamento do processo é comparado com o do modelo e qualquer desvio no processo, não previsto pelo modelo que o representa, é indicado como falha. A modelagem do processo pode ser feita pela modelagem fenomenológica, dados, o chamado conhecimento explícito. A forma com que se pode realizar o monitoramento do processo depende da forma como seu modelo foi construído. A figura 1 ilustra as diferentes formas de monitoramento, com base na forma em que o modelo que representa o processo foi construído.

Figura 1 – Métodos de controle de processos com base no tipo de conhecimento



Fonte: Adaptado de Aldrich e Auret (2013)

Os métodos que advêm do conhecimento explícito estão bastante difundidos na literatura, sendo o processo de detecção de falhas abordado geralmente através da construção de modelos do processo. Este método é especialmente aplicado a processos mais simples, quando é possível definir o modelo pelas equações que definem o processo.

Em Venkatasubramanian et al. (2003) são abordadas formas distintas de monitoramento e detecção de falhas utilizando modelos do processo, tais como observadores de estados, filtros de Kalman, equações de paridade, entre outros. Em Isermann (2005) é feito um estudo sobre os métodos baseados em modelos para detecção, focado nos observadores e equações de paridade como método de detecção de falha. Quando se utiliza tais modelos, a detecção é feita sobre os resíduos de um determinado conjunto de variáveis, gerados pela comparação do comportamento atual da variável com o esperado pelo modelo.

Com o aumento da complexidade dos processos reais, a criação de um modelo que o representasse se torna uma tarefa dispendiosa em tempo e esforço, tornando esta abordagem não muito prática. Com isso, entra-se na outra vertente do conhecendo explícito, presente na figura 1, a utilização dos dados históricos do processo com as chamadas Estatísticas Multivariadas de Controle de Processos (MSPC – *Multivariate Statistical Process Control*). De acordo com Kourti (2002), os conjuntos de dados geralmente são enormes, altamente correlacionados com várias variáveis, colineares e de natureza não causal, pouca informação devido à baixa razão sinal-ruído e medidas perdidas em algumas variáveis. Por mais de uma década, pesquisadores vem concentrando esforços no desenvolvimento de modelos que utilizam métodos baseados em variáveis latentes, tais como a Análise de Componentes Principais (PCA – *Principal Component Analysis*) e a Projeção em Estruturas Latentes ou Mínimos Quadrados Parciais (PLS – *Partial Least Squares*), com esses métodos endereçando todas as questões acima de maneira direta e fornecendo ferramentas para análise que são fáceis de interpretar (KOURTI, 2002). Com o passar dos anos diversas aplicações foram desenvolvidas utilizando os métodos PCA e PLS para o monitoramento, tendo em Zhang (2000), uma discussão e aplicação de ambos os métodos, assim como em Yoon e MacGregor (2001). Variantes de ambos os métodos também são utilizados, a depender das características da aplicação em que ele está presente. Em Li et al. (2000) é aplicado o método PCA com características recursivas para se adaptar a mudanças no processo. Essa abordagem falha em distinguir mudanças de região de operação, que no caso são mudanças mais bruscas das variáveis do processo, de falhas, limitando sua aplicação. Uma gama maior de variações é apresentada em Aldrich e Auret (2013), mostrando também a utilização da Análise de Componentes Independentes (ICA – *Independent Component Analysis*) para o monitoramento de processos multivariados.

As aplicações, dos métodos PCA e PLS, são utilizadas para processos que permanecem em um mesmo estado estacionário, fugindo da realidade de grande parte dos processos industriais existentes. Mesmo suas variantes dinâmicas e adaptativas ainda sofrem para detecção de falha quando ocorre a mudança de região de operação do processo, com a possibilidade do processo até se adaptar a ocorrência de uma falha, no caso adaptativo. Com isso, vem a necessidade da construção de um sistema que consiga realizar um monitoramento eficiente nas mais diversas condições operacionais do processo, distinguindo a mudança de operação de uma falha. Posterior a visualização deste problema, começaram a serem desenvolvidas técnicas para atacá-lo que passam desde a utilização de múltiplos modelos, sendo um modelo para cada condição operacional, presente em Zhao, Zhang e Xu (2004), a separação em subespaços, sendo um com a informação comum a todas as condições operacionais e outros com a informação específica de cada condição, presente em Zhang, Wang e Lu (2013). A técnica utilizada por Kano et al. (2004), denominada de análise externa, consegue unir os dois aspectos presentes no conhecimento explícito endereçando questão de múltiplas regiões de operação. A análise externa utiliza os dados históricos do processo para construir modelos com estruturas lineares ou não lineares, que representem as mudanças de região de operação e o monitoramento, utilizando as técnicas de MSPC, é realizado no resíduo resultante da comparação entre o estimado pelo modelo e a medição real no processo. Na literatura existem aplicações da análise externa, tais como em Ge et al. (2008) na qual é construído um modelo não linear para explicar as mudanças de região de operação e o monitoramento é feito através de um conjunto com as técnicas PCA e ICA, e em Zheng, Qin e Chai (2016) onde é utilizada a análise externa e também uma variante do PLS para monitoramento do processo.

Devido as técnicas de detecção de falhas convencionais considerarem o processo operando em uma única região de operação, tornam-se inviáveis suas aplicações em processos mais modernos, que atuam em diversas regiões. Por isso, é necessário o estudo e validação de técnicas para detecção de falhas e monitoramento de processos em diversas regiões de operação. Este estudo inclui não somente técnicas estatísticas para o monitoramento multivariado de processos, mas também modelos, com diferentes estruturas, que consigam explicar comportamento do processo nas suas mais diversas faixas de operação. Busca-se assim assegurar um bom monitoramento do processo, evitando falsos alarmes, perdas e paradas de planta desnecessárias.

O objetivo deste trabalho consiste na avaliação de diferentes modelos para detecção de falhas utilizando técnicas baseadas em análise externa, aplicadas em um *benchmark* simulado e em um ventilador industrial. No capítulo 2 é feita a revisão de literatura. No capítulo 3 faz-se uma discussão sobre os estudos de caso, seguido do capítulo 4 no qual é feita a aplicação das metodologias nos estudos de caso. Por fim, a conclusão obtida com base nos resultados está presente no capítulo 5.


2 REVISÃO DA LITERATURA

Neste capítulo é apresentada uma revisão sobre os conceitos utilizados ao longo do trabalho. Na seção 2.1 são discutidos os métodos estatísticos univariados para monitoramento de processos. A seção 2.2 traz a vertente multivariada dos métodos estatísticos para monitoramento de processos, com uma descrição dos principais métodos utilizados na literatura. Na seção 2.3 é apresentada uma metodologia de detecção de falhas utilizando a análise de componentes principais. A seção 2.4 traz uma descrição sobre a detecção de falhas baseadas em modelos. A última seção do capítulo, 2.5, traz uma técnica para realizar o procedimento de detecção de falhas em processos que operam em múltiplas regiões de operação.

2.1 ANÁLISE UNIVARIADA

As cartas de controle estatístico univariado tais como carta de Shewhart, CUSUM e EWMA, são bem estabelecidas como métodos estatísticos para monitoramento de variáveis de processos estáveis (KOURTI; MACGREGOR, 1995). O mais antigo método é a carta de Shewhart, que consiste em um gráfico sequencial das observações em que se tem uma variável de qualidade a ser seguida e limites superior e inferior. A definição de ambos os limites é crítica para limitação da quantidade alarmes indevidos durante o monitoramento do processo, indicações de falha quando não há ocorrência, assim como durante a ocorrência de uma falha a carta de controle não indicar que ocorreu uma alteração no processo. Então, os limites devem ser definidos de tal maneira que se busque minimizar as duas indicações. A figura 2 ilustra o monitoramento via carta de Shewhart.

Figura 2 – Ilustração da carta de controle de Shewhart. Os pontos são observações



Fonte: Adaptado de Chiang, Russel e Braatz (2000)

Assumindo que a variável a ser monitorada tenha uma distribuição estatística próxima da normal, com média μ e desvio padrão σ , os limites de confiança são expressos através da equação (1)

$$\mu - c_{\frac{\alpha}{2}}\sigma \leq x \leq \mu + c_{\frac{\alpha}{2}}\sigma \quad (1)$$

onde $c_{\frac{\alpha}{2}}$ é o desvio padrão normal correspondente ao nível de confiança desejado, definido por $(1 - \alpha)$. A quantidade de desvios padrões a ser utilizada nos limiares é calculada usando o gráfico de distribuição acumulada da variável. O monitoramento de processos baseado nas cartas de Shewhart podem não fornecer uma quantidade adequada de falsos alarmes e de detecções perdidas, não tendo sensibilidade suficiente para detecção da falha. Essas taxas podem ser melhoradas utilizando observações de múltiplos instantes consecutivos anteriores, tais como ocorre nas cartas de soma cumulativa (CUSUM – *Cumulative Sum*), proposta por Page (1954), e a carta de média móvel exponencial (EWMA – *Exponentially Weighted Moving Average*), proposta por Roberts (1959).

A carta de controle de Shewhart é efetiva quando se tem uma mudança na variável na ordem de dois desvios padrões ou maior, não sendo tão efetiva para mudanças menores. Nesse contexto, a carta de controle CUSUM é uma boa alternativa quando se precisa detectar pequenas mudanças (MONTGOMERY, 2009). Supondo que uma amostra de tamanho $n > 1$ é coletada, e \bar{x}_j é o valor da j -ésima amostra. Se a meta do processo é representada por μ_0 , a carta de controle CUSUM é dada pela equação (2)

$$C_i = \sum_{j=1}^i (\bar{x}_j - \mu_0) \quad (2)$$

Caso o processo esteja centrado na sua média, μ_0 , a soma cumulativa se torna um valor próximo de zero. Entretanto, caso ocorram mudanças na média ou tendências na variável monitorada, a soma cumulativa irá seguir aumentando para cima ou para baixo, a depender da direção da mudança. Isso faz com que a carta de controle CUSUM seja mais efetiva que a carta de Shewart para detectar pequenas mudanças na média da variável, que não violem o limiar de controle estabelecido, e também de tendências sobre a mesma.

Outra alternativa a carta de Shewhart para detectar pequenas mudanças é carta de controle EWMA. O desempenho de tal carta de controle é aproximadamente equivalente ao da carta de controle CUSUM, sendo mais fácil sua implementação (MONTGOMERY, 2009). A média móvel exponencial com pesos é calculada pela equação (3)

$$z_i = \lambda x_i + (1 - \lambda)z_{i-1} \quad (3)$$

onde λ possui valores entre 0 e 1, sendo o valor constante durante o monitoramento e o valor inicial da carta de controle é definido com a meta da variável. Em Montgomery, (2009) é demonstrado o cálculo dos limiares para ambas cartas de controle assim como aplicações das mesmas na detecção de pequenas mudanças nas variáveis do processo.

O monitoramento de processos baseados somente na carta de Shewhart pode não ter uma taxa de detecção adequada, justamente pela baixa sensibilidade a pequenas mudanças na variável. As cartas de controle CUSUM e EWMA trazem uma melhora nessas taxas e uma maior sensibilidade no monitoramento, mas tal melhoria vem às custas de atrasos nos momentos de detecção de anormalidades, já que ambas as técnicas são dependentes de instantes anteriores do processo, não somente do atual. Assim, pode se dizer que as cartas CUSUM e EWMA são melhor aplicadas na detecção de falhas que produzem pequenas variações persistentes nas variáveis, mudanças de média ou tendências, enquanto a carta de Shewhart é melhor aplicada na detecção de grandes mudanças abruptas na variável (CHIANG; RUSSEL; BRAATZ, 2000).


As cartas de controle estatístico univariado de processos determina limites para cada observação da variável individualmente, sem considerar a informação que existe nas outras variáveis, ignorando a correlação entre as variáveis, não conseguindo representar

então corretamente comportamento da maioria dos processos industriais modernos. Para essa situação, foram desenvolvidas as técnicas para controle estatístico multivariado, que levam em conta a correlação existente entre as variáveis do processo para realizar o monitoramento do mesmo.

2.2 ANÁLISE MULTIVARIADA

A correlação entre as variáveis do processo existe pelos sensores de monitoramento estarem presentes em diferentes etapas do processo e etapas que são interdependentes. Assim, um sinal medido no início do processo pode ter uma correlação com sinais de medições de etapas próximas. Por não considerar tais correlações, os métodos univariados para detecção de falhas não tem sensibilidade suficiente para detectar grande parte das falhas em processos industriais modernos, já que uma falha não afeta somente uma única variável, e sim um conjunto de variáveis. Esse fato é visto na figura 3, onde são ilustradas duas séries univariadas, y_1 e y_2 . O comportamento univariado de ambas permanece dentro dos limiares definidos, com exceção do momento da marcação em vermelho. Quando se analisa o comportamento levando em conta a correlação entre ambas as séries, mesmo uma observação dentro dos limites univariado, em verde, pode estar fora da normalidade quando é feita a análise multivariada. Assim como uma observação fora dos limites univariados, pode estar dentro da normalidade quando é feita a análise multivariada.

Figura 3 – Monitoramento univariado em comparação com o multivariado



Fonte: Adaptado de Kourti (2002)

A ideia principal da análise multivariada é extrair informação dos dados originais e construir estatísticas para monitoramento. A maioria dos métodos para análise multivariada consegue trabalhar com dados com altas dimensões e correlacionados (GE; SONG, 2012). Para redução da dimensão dos dados originais, os métodos mais comuns para o monitoramento de processos são a PCA, o PLS e a ICA.

2.2.1 PCA

A aplicação do método PCA como uma ferramenta para se realizar o monitoramento de processos industriais é um tema recorrente na literatura, como pode ser visto em Zhang (2000), Kano et al. (2001), Yoon e MacGregor (2001), Alcalá e Qin (2008) e Zuqui et al. (2016). De acordo com Chiang, Russel e Braatz (2000), a aplicação da técnica PCA para um determinado monitoramento se deve a um ou mais de três fatores: redução de dimensionalidade, a estrutura da análise de componentes principais pode ser utilizada para encontrar as variáveis responsáveis ou as mais afetadas pela ocorrência de uma falha e também pode separar o espaço das observações das variáveis em um subespaço contendo informações e tendências do processo e um outro subespaço contendo somente ruído branco.

Seja um conjunto de dados $X^{n \times m}$, onde n é o número de amostras e m a quantidade de variáveis do processo. Assumindo que os dados tenham média zero e variância unitária, a matriz de covariância amostral de X é definida pela equação (4)

$$S = \frac{X^T X}{n - 1} \quad (4)$$

Realizando a decomposição por autovalores sobre a matriz de covariância amostral S , tem-se a equação (5)

$$S = \frac{X^T X}{n - 1} = V \Lambda V^T \quad (5)$$

onde Λ é a matriz diagonal contendo os autovalores de S e a matriz V é a matriz ortogonal de autovetores associada a Λ . A magnitude dos autovalores é correspondente a variância de S retida por aquela componente. Para realizar a redução de dimensionalidade, somente os autovetores correspondentes aos maiores autovalores são retidos na matriz de carregamento $P^{m \times a}$, onde a é o número de componentes retidas. Em Chiang, Russel e Braatz (2000) são demonstrados alguns métodos para escolha do número de componentes

a serem retidas. A projeção dos dados da matriz X no subespaço de menor dimensão é obtido através da matriz de *scores*, ilustrada pela equação (6)

$$T = XP \quad (6)$$

O subespaço residual é calculado através da equação (7)

$$E = X - \hat{X} \quad (7)$$

onde \hat{X} é a projeção de T no espaço de dimensão m original.

2.2.2 PLS

O princípio do método PLS para monitoramento é similar ao do PCA, com exceção de que o PLS também incorpora a informação das variáveis de qualidade no processo, formando o conjunto $\{X, Y\}$ de dados (GE; SONG, 2012). É uma técnica também utilizada para redução de dimensionalidade que maximiza a covariância entre o preditor, X , e o predito, Y , para cada componente do espaço reduzido (CHIANG; RUSSEL; BRAATZ 2000). O objetivo do PLS é a decomposição de X e Y em uma combinação da matriz de *scores* T , de carregamento P e Q e de pesos W . As relações de decomposição de X e Y são expressas pelas equações (9) e (10)

$$X = T^T P + E \quad (9)$$

$$Y = T Q^T + F \quad (10)$$

A matriz de regressão, R , do modelo PLS, que relaciona as variáveis de qualidade com as variáveis de processo é determinada pela equação (11)

$$R = W(P^T W)^{-1} Q^T \quad (11)$$

O método de cálculo da matriz de peso, carregamento e de scores, assim como aplicação do PLS para monitoramento de processos é demonstrado em Chiang, Russel e Braatz (2000). Para aplicação dos métodos PLS e PCA, assume-se que as variáveis têm comportamento gaussiano, sendo regida somente por estatísticas de até segunda ordem. Caso as variáveis do processo tenham um comportamento que pode ser considerado não gaussiano, é necessária a utilização de um outro método para monitoramento e redução da dimensionalidade do sinal, sendo o método ICA um dos mais recomendados na literatura.

2.2.3 ICA

A análise por componentes independentes é uma técnica computacional e estatística para revelar fatores ocultos que compõem conjuntos de variáveis aleatórias, medidas ou sinais (GE; SONG, 2012). A principal motivação no uso do ICA para monitoramento é que o próprio monitoramento pode ter seu desempenho aumentado se focando somente nas variáveis essenciais, que guiam o processo (KANO et al, 2004). Seja um conjunto de dados X com m variáveis, ele pode ser expresso por uma combinação linear de r componentes independentes, onde $r \leq m$. Na equação (12) é mostrada a relação entre o conjunto de dados e as componentes independentes

$$X^T = AS + E \quad (12)$$

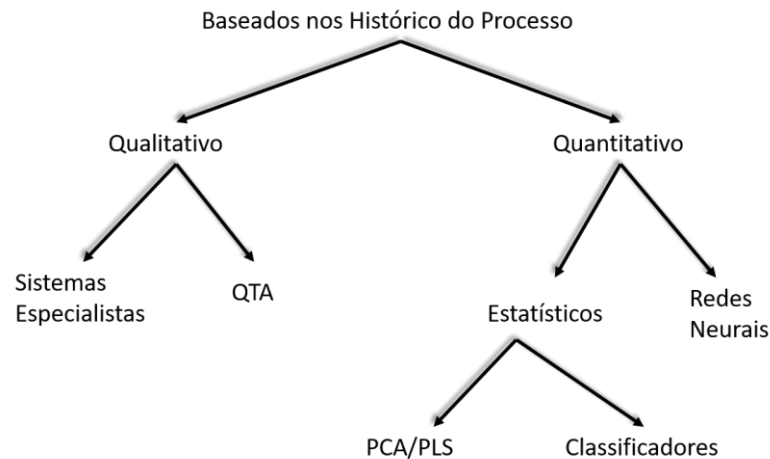
onde X é a matriz de dados, A a matriz de mistura e S a matriz de componentes independentes. O algoritmo FastICA, proposto por Hyvarine e Oja (2000), realiza o cálculo das matrizes A e S , onde assume-se que as componentes independentes têm distribuições não gaussianas e são linearmente independentes. Para escolha da quantidade de componentes independentes retidas, aquelas que detêm maior quantidade de informação não gaussiana do processo, são utilizadas estatísticas de alta ordem, tais como curtose e entropia diferencial.

Os métodos citados nesta seção são amplamente utilizados para monitoramento de processos e, conseqüentemente, detecção de falhas. O monitoramento é realizado através de estatísticas multivariadas, sendo a estatística T^2 e Q utilizadas quando é feito o monitoramento pelos métodos PCA ou PLS e a estatística I^2 quando se utiliza o método ICA. Neste trabalho, para detecção de falhas, serão utilizados modelos PCA, sendo ele aplicado nos estudos de caso apresentados no capítulo 3 e nas aplicações do capítulo 4.

2.3 DETECÇÃO DE FALHAS BASEADO EM DADOS – MÉTODO PCA

A utilização dos métodos citados na seção anterior para efetiva detecção de falhas depende somente de dados históricos dos processos, não sendo necessário nenhum prévio conhecimento do sistema. Em Venkatasubramanian et al. (2003) é apresentado um estudo sobre métodos de detecção de falhas baseados em dados históricos, sendo os principais métodos ilustrados na figura 4.

Figura 4 – Classificação dos métodos baseados no histórico do processo



Fonte: Adaptado de Venkatasubramanian et al. (2003)

Um dos diversos modos para se realizar o monitoramento de processos com base em dados históricos é a abordagem por modelos PCA ou PLS, ambos com aplicações de maneira semelhante. O método PCA, inicialmente proposto por Pearson (1901) e posteriormente aprimorado por Hotelling (1947) é a técnica multivariada padrão e está incluída em diversos livros e artigos com o passar das décadas (VENKATASUBRAMANIAN et al, 2003). Ele retém somente as componentes com maior variância do processo e com essa informação são calculadas estatísticas para se realizar o monitoramento do processo, sendo as mais difundidas na literatura a estatística T^2 de Hotelling e a estatística Q .

A estatística T^2 mede a variação nos componentes principais do modelo PCA de monitoramento. Ela é calculada pela equação (13)

$$T^2 = x^T P \Lambda^{-1} P^T x \quad (13)$$

Para aferir se um processo está em estado de normalidade, é necessário a construção de um limiar que indique quando ocorreu alguma variação no processo que pode ser considerada uma falha. Esse limiar é calculado com os mesmos dados de normalidade utilizados na construção do modelo PCA. O cálculo do limiar é expresso pela equação (14)

$$T_\alpha^2 = \frac{l(N-1)}{N-1} F_{l, N-l, \alpha} \quad (14)$$

onde l é o número de componentes retidas, N a quantidade de amostras e α é o nível de significância desejado. Caso a quantidade de amostras N seja tão grande que a média e a covariância do processo possam ser estimadas corretamente, o limiar de T^2 pode ser aproximado por uma distribuição χ^2 com l graus de liberdade, expressa pela equação (15)

$$T_{\alpha}^2 = \chi_{l;\alpha}^2 \quad (15)$$

O monitoramento também pode ser realizado nas componentes principais não retidas, no resíduo do modelo PCA. Esse monitoramento é realizado através da estatística Q e é feito em conjunto com a T^2 , pois pode ocorrer de algumas falhas só se manifestarem fora das componentes principais do modelo PCA. O cálculo da estatística Q é expresso pela equação (16)

$$Q = ||\tilde{x}||^2 = ||(I - PP^T)x||^2 \quad (16)$$

Assim como a estatística T^2 , a estatística Q possui um limiar indicando quando o processo está em condição de normalidade. Quando a estatística ultrapassa esse limiar, é indicada falha no processo. Em Qin (2003) é demonstrado como é feito o cálculo do limiar por duas formas diferentes. Uma das formas do cálculo do limiar é dada pela equação (17)

$$\delta_{\alpha}^2 = g\chi_{h;\alpha}^2 \quad (17)$$

onde os parâmetros são calculados pelas equações (18), (19) e (20)

$$g = \frac{\theta_2}{\theta_1} \quad (18)$$

$$h = \frac{\theta_1^2}{\theta_2} \quad (19)$$

$$\theta_i = \sum_{j=l+1}^m \lambda_j^i \quad i = 1, 2, 3 \dots \quad (20)$$

onde $\lambda_j, j = l + 1, \dots, m$, correspondem aos autovalores das componentes não retidas pelo modelo PCA. Por monitorar as componentes não retidas, a estatística Q tem um papel diferente da estatística T^2 no monitoramento do processo. De acordo com Qin (2003) a estatística Q mede variações que quebrem a correlação natural do processo, indicando uma falha, enquanto a estatística T^2 monitora a distância em relação a origem, a normalidade do processo, de uma observação. Devido as componentes principais serem

as que contém a maior variância do processo, somente uma variação nas observações maior que a definida como normal do processo deverá ser indicada como falha, ou seja, para estatística T^2 indicar a ocorrência de uma falha a magnitude da variação do processo tem de ser grande. Em contrapartida, por conter somente as componentes de menor variância a estatística Q é mais sensível a pequenas variações no processo. Por então serem complementares, foi proposto um único índice por Yue e Qin (2001), a combinação da estatística Q com a T^2 , utilizando somente um único sinal para monitorar as situações em que ambas eram necessárias. A combinação é dada pela equação (21)

$$\varphi = \frac{Q}{\delta_\alpha^2} + \frac{T^2}{\chi_{l;\alpha}^2} = \mathbf{x}^T \Phi \mathbf{x} \quad (21)$$

onde φ é o índice combinado e Φ é expresso pela equação (22)

$$\Phi = \frac{P \Lambda^{-1} P^T}{\chi_{l;\alpha}^2} + \frac{\tilde{P} \tilde{P}^T}{\delta_\alpha^2} \quad (22)$$

onde a matriz \tilde{P} é composta pelas colunas da matriz de carregamento correspondentes a componentes não retidas pelo modelo PCA. O cálculo do limiar estatístico é demonstrado em Qin (2003).

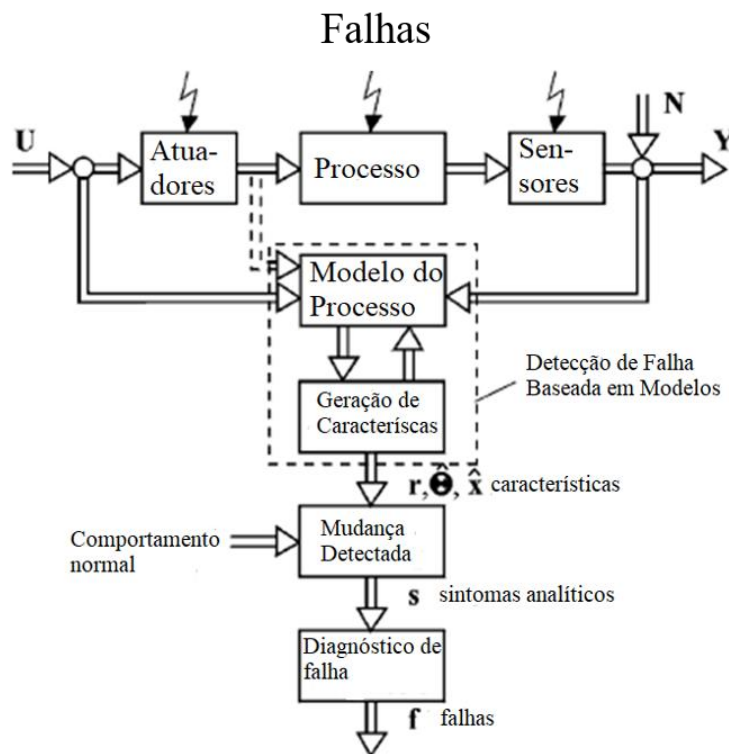
Em resumo, a utilização da informação gerada pelo modelo PCA, com as estatísticas de monitoramento acima propostas que fazem com que variações, fora do que o modelo PCA foi treinado para considerar normal, sejam indicadas como falha e assim fornecendo um primeiro indício para resolução do problema. A utilização de dados históricos não é a única forma de se modelar e conhecer o comportamento de um processo. Caso sejam conhecidas as equações físicas que determinem o seu funcionamento, é possível modelar o seu funcionamento e utilizar este modelo para realizar o monitoramento do processo.

2.4 DETECÇÃO DE FALHAS BASEADO EM MODELOS

A utilização de modelos para detecção de falhas tem sido bastante estudada nas últimas décadas. De acordo com Isermann (2005), a tarefa do monitoramento utilizando modelos consiste na detecção de falhas em processos, atuadores e sensores usando as dependências entre os diferentes sinais medidos, que podem ser expressas por modelos matemáticos. Os modelos podem variar desde os mais simples, com somente uma única

entrada e uma única saída para aqueles mais complexos, que englobam múltiplas entradas e saídas do processo. A detecção de falhas pode ser feita de formas distintas, sendo as principais pela comparação entre a saída do modelo e do processo para uma determinada entrada, gerando resíduos, a verificação de mudanças nos parâmetros do modelo ou mudança nos estados do processo. A figura 5 mostra um esquema geral do processo de detecção de falha baseado em modelos do processo.

Figura 5 – Esquema geral para detecção e diagnóstico de falhas baseados em modelos



Fonte: Adaptado de Isermann (2005).

A equação (23) representa o monitoramento por geração de resíduos

$$y(t) = f(u(t), w(t), x(t), \theta(t)) \quad (23)$$

onde $y(t)$ e $u(t)$ denotam as saídas e entradas medidas do processo, $x(t)$ as variáveis de estado, $w(t)$ distúrbios no processo e $\theta(t)$ os parâmetros do processo, com o resíduo sendo gerado pela comparação entre o medido e o estimado pela saída $y(t)$. Uma falha no processo causa mudanças nos estados dos mesmo e/ou nos seus parâmetros. Em Venkatasubramanian et al. (2003) é citado que o filtro de Kalman ou outros tipos de observadores são largamente utilizados para estimação de estados, assim como os mínimos quadrados é uma ferramenta poderosa para estimação de parâmetros e mais

recentemente, as equações de paridade também vêm sendo utilizadas para geração de resíduos no monitoramento de processos via modelos. Todos estes métodos dependem de prévio conhecimento do modelo do processo ou de conhecimento sobre as equações físicas que representem o mesmo para que o modelo possa ser estimado com a maior acurácia possível.

O filtro de Kalman é um algoritmo recursivo para estimação dos dados de um modelo. Sua aplicação para detecção de falhas é estimar os estados com mínimo erro de estimação, durante a operação normal do processo. O resíduo gerado entre a comparação dos estados do processo com o estimado pelo filtro de Kalman é utilizado para detectar alterações que fazem o processo sair de seu estado normal.

As equações de paridade são uma reorganização dos modelos entrada-saída ou de espaço de estados da planta. Elas são utilizadas para checar o quão consistente são os sinais medidos na planta com os previstos pelas equações para uma entrada conhecida do processo. O resíduo gerado, a diferença entre o medido e o fornecido pelas equações de paridade, em operação normal é próximo de zero devido a erros nos sensores, ruídos nas medições e precisão do modelo.

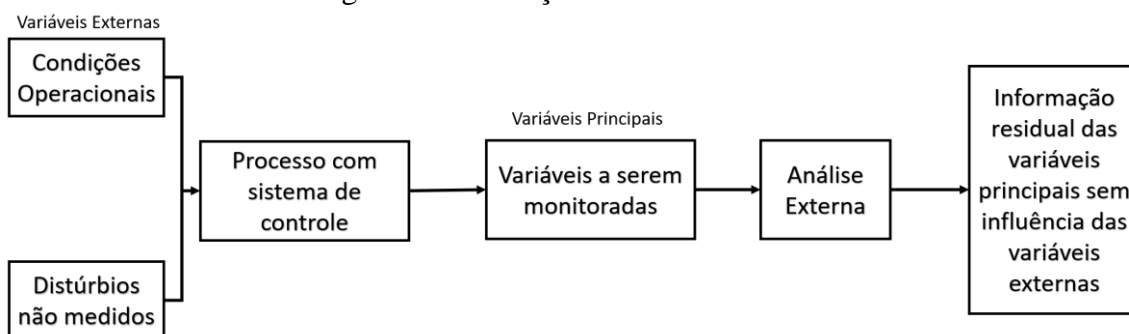
Em Venkatasubramanian et al. (2003) os métodos são aprofundados e exemplos são tratados. Após a geração do resíduo, é necessário a utilização de métodos que mostrem quando o resíduo está dentro do normal ou se seu comportamento difere do proposto pelo modelo. Para isso podem ser utilizados limiares estatísticos ou classificadores na avaliação.

Os mesmos conceitos utilizados para detecção de falhas por modelos, a geração de resíduos para monitoramento do processo, também pode ser utilizada para outros tipos de aplicações, sendo uma delas visualizada por Kano et al. (2004), endereçando a questão de processos que operem em diversas regiões de operação. São utilizados modelos estimados com base nos dados históricos do processo, que consigam explicar as variações de condição operacional do processo, uma técnica que definida como Análise Externa. Todo o monitoramento posterior é feito utilizando os resíduos, que não contém mais a influência de mudanças de condição operacional do processo, utilizando as técnicas clássicas de monitoramento univariado ou multivariado.

2.5 ANÁLISE EXTERNA

Processos industriais reais raramente são estacionários, permanecendo em um único ponto de operação. Para um modelo PCA treinado somente para uma única região de normalidade, uma mudança nas condições operacionais é indicada como falha pela estatística utilizada para o monitoramento, se tornando necessário diferenciar as mudanças de região de operação de falhas sobre o processo. Em Kano et al. (2004) é definido que as condições operacionais de uma planta são definidas por fatores externos ao processo, tais como vazões de entrada e *setpoint* de controladores. Assim, as variáveis monitoradas de um processo são divididas em dois grupos distintos, um com as variáveis responsáveis pelas mudanças nas condições operacionais da planta, chamadas de variáveis externas, e outro grupo somente com as variáveis afetadas por mudanças nas condições operacionais, as variáveis principais. Como as mudanças de região de operação devem ser distinguidas de falhas no processo, a influência das variáveis externas deve ser retirada das variáveis principais, tornando o monitoramento robusto a mudança de região de operação. Todo o processo de análise externa é ilustrado pela figura 6.

Figura 6 – Descrição da análise externa



Fonte: Adaptado de Ge et al. (2008)

Considerado a matriz de dados $Z^{n \times m}$, onde n é o número de amostras e m o número de variáveis, a matriz de dados então pode ser dividida nas duas categorias de variáveis, externas e principais, ficando na forma da equação (24)

$$Z = [Y \ U] \quad (24)$$

onde Y é o conjunto das variáveis principais e U o conjunto das variáveis externas. A matriz Y é composta também por duas partes, uma explicada pelas variáveis externas, e outro não explicada, fato ilustrado pela equação (25)

$$Y = f(U) + e \quad (25)$$

onde $f(U)$ é o modelo que gera uma estimativa de Y com base em U , as variáveis externas, e e os resíduos do modelo que relaciona os dois conjuntos de variáveis, a parte não explicada pelas variáveis externas. Para modelos lineares, pode-se aplicar regressão múltipla por mínimos quadrados para cálculo do modelo. Com isso, a estrutura do modelo $f(U)$ é ilustrado pela equação (26)

$$f(U) = U\theta \quad (26)$$

sendo θ a matriz de coeficientes do modelo, que é calculada pela equação (27)

$$\theta = (U^T U)^{-1} U^T Y \quad (27)$$

Quando se aplica análise externa, o monitoramento é feito sobre os resíduos do modelo que relaciona os dois conjuntos de variáveis, a parte não explicada pelas variáveis externas. Outros métodos de regressão lineares também podem ser aplicados, como o PLS, que é mais recomendado caso existam conjuntos de dados colineares.

Quando se realiza o monitoramento de um processo não linear, a utilização de regressão linear, como mínimos quadrados e/ou PLS, pode não ter resultados satisfatórios quando ocorre mudanças na região de operação do processo, tornando a magnitude do resíduo alta. Para isso, é necessário alterar a estrutura do modelo $f(U)$ para que ele seja capaz de lidar também com a informação não linear. Uma aplicação de análise externa com modelo não linear pode ser vista em Ge et al. (2008), onde é utilizada a regressão por vetores de suporte (SVR – *Support Vectors Regression*) na construção do modelo do processo.

O conceito de análise externa apresentado acima não leva em consideração a dinâmica do processo para a construção dos modelos, tornando os modelos estáticos. Quando é necessário levar em consideração a dinâmica do processo, utiliza-se medidas de instantes anteriores além do instante atual. Isso faz com que uma alteração nas matrizes de variáveis principais e de variáveis externas, na forma das equações (28), (29) e (30), seja necessária

$$Y = Y_0 = \begin{bmatrix} y(s) \\ \vdots \\ y(k-1) \\ y(k) \end{bmatrix} \quad (28)$$

$$U = [U_0 \ U_1 \ \dots \ U_{s-1}] \quad (29)$$

$$U_i = \begin{bmatrix} u(s-1) \\ \vdots \\ u(k-1-i) \\ u(k-i) \end{bmatrix} \quad (30)$$

onde s é a quantidade de atrasos, medições anteriores a serem consideradas. Por esse processo, os dados das variáveis externas utilizados para estimar o valor de $y(t)$ seriam $u(t), u(t-1), u(t-2), \dots, u(t-s+1)$ e assim sucessivamente para outros instantes de tempo. De acordo com Kano et al. (2004) a quantidade de atrasos s pode ser selecionada por correlação cruzada entre as variáveis externas e variáveis principais e que a identificação do modelo dinâmico é semelhante ao processo para identificação de um modelo por resposta ao impulso. Os atrasos também podem ser incluídos no modelo de detecção de falhas, PCA ou PLS. No caso, seriam utilizadas as variantes dinâmicas de ambos, a análise de componentes principais dinâmica (DPCA – *Dynamic Principal Components Analysis*) e os mínimos quadrados parciais dinâmicos (DPLS – *Dynamic Partial Least Squares*).

No contexto deste trabalho, algumas estruturas de modelos foram selecionadas para serem utilizadas nas seções a seguir. O modelo mais simples a ser utilizado, possui a estrutura dada pela equação (31)

$$y = ax + b \quad (31)$$

onde a e b são parâmetros calculados através da equação (27), sendo $\theta = [a \ b]$. Uma das formas de se aumentar a complexidade do modelo é através do acréscimo de atrasos, se tornando um modelo que represente a dinâmica do processo. A estrutura de tal modelo é dada pela equação (32)

$$y = b + a_0x(t) + a_1x(t-1) + a_2x(t-2) + \dots + a_{s-1}x(t-s) \quad (32)$$

Para representação da não linearidade presente em alguns processos, fatores polinomiais serão acrescentados, tanto na estrutura da equação (31), quanto na estrutura da equação (32).

A equação (33) ilustra como fica a estrutura do modelo linear com os fatores polinomiais, se tornando um modelo não linear,

$$y = b + a_0x^1 + a_1x^2 + a_2x^3 + \dots + a_{p-1}x^p \quad (33)$$

onde p é a ordem do polinômio que se quer utilizar. A representação da não linearidade, também pode ser feita através das redes neurais, e neste trabalho será utilizada a rede neural com a topologia da *General Regression Neural Network* (GRNN), com estrutura e definição presentes em Spetch (1991).

A atuação em conjunto da análise externa com o método PCA para monitoramento faz com que seja possível detectar falhas no processo em qualquer ponto de operação que o mesmo se encontre. Todo monitoramento, aplicação da técnica PCA e cálculo das estatísticas, é feito sobre os resíduos gerados pela análise externa, que sofrem variações somente durante a ocorrência de falhas no processo. As desvantagens do uso de análise externa é que qualquer variação sobre as variáveis externas não é considerada uma falha, mesma que essa variação seja causada por uma, além da escolha do modelo adequado para relacionar os dois conjuntos de variáveis.

2.6 METODOLOGIA

A metodologia será um guia para toda a aplicação presente neste trabalho. É nela que são definidos como serão feitas as aplicações e que tipo de resultado será obtido. Para o caso da detecção de falhas em processos industriais operando em múltiplos pontos de operação, a utilização da análise externa faz com que seja necessário processos antes da construção do modelo de detecção de falha. Com isso, a metodologia será dividida nos seguintes pontos:

- Seleção das variáveis externas
- Seleção dos dados de treinamento
- Treinamento dos modelos
- Métricas calculadas e geração dos resíduos
- Construção do modelo estatístico de monitoramento

A seleção das variáveis externas passa pela identificação de quais variáveis são de entrada no processo, ou que não sofram influência de outras variáveis. Nessa categoria, como dito na seção 2.5, as variáveis de entrada podem ser *setpoints* de controladores, fluxos de entrada. Com os conjuntos de variáveis definidos, das externas e das principais, é necessária a seleção dos dados com que será feito o treinamento dos modelos. O conjunto de dados tem que ser tal que possua variações nos sinais, que torne possível o treinamento do modelo. No caso de o modelo a ser treinado necessitar capturar a dinâmica do processo, a variação nos dados de treinamento não pode ser suave o suficiente para que a influência da dinâmica seja praticamente nula.

Com os dados de entrada do modelo, as variáveis externas, os dados de saída, as variáveis principais, o treinamento do modelo se dá geralmente utilizando a técnica dos mínimos quadrados, expressa pela equação (27). Para modelos com características não lineares, tais como modelos polinomiais de ordem maior que um, é necessário o acréscimo de colunas matriz U, que represente as parcelas não lineares do modelo.

A geração dos resíduos, a informação dos dados sem a influência das variáveis externa é obtida pela subtração da parte estimada pelo modelo dos dados originais. O processo segue a linha da figura 6. Para verificar a qualidade do modelo, será calculada a sua norma euclidiana, de acordo com a equação

$$||x|| = \sqrt{x_1^2 + x_2^2 + x_3^2 + \dots + x_n^2} \quad (34)$$

Por ser um desvio, a norma dos resíduos se torna a raiz da soma do erro quadrático, um valor que quanto mais próximo de zero, maior a qualidade do modelo. A construção do modelo estatístico de monitoramento é feita utilizando os resíduos, sem influência das mudanças de operação do processo. Caso seja gerado resíduos para mais de uma variável, será construído um modelo PCA e utilizada a estatística combinada para monitoramento, com um limiar de 99% de confiança. Se somente o resíduo de uma variável for monitorado, será feito um limiar univariado, também com 99% de confiança.

A medição do desempenho do modelo será feita pelo cálculo do tempo de detecção da falha de cada modelo. Quando possível, será calculado o tempo médio de detecção de um conjunto de simulações, semelhante como é feito em Kano, (2004) em sua primeira aplicação. A medição de falsos alarmes durante o período de operação normal somente

será calculada se alguma informação importante puder ser dita por ela, como na comparação entre modelos. Caso contrário, somente a norma dos resíduos e o tempo médio de detecção de falha serão utilizados na comparação entre os modelos.

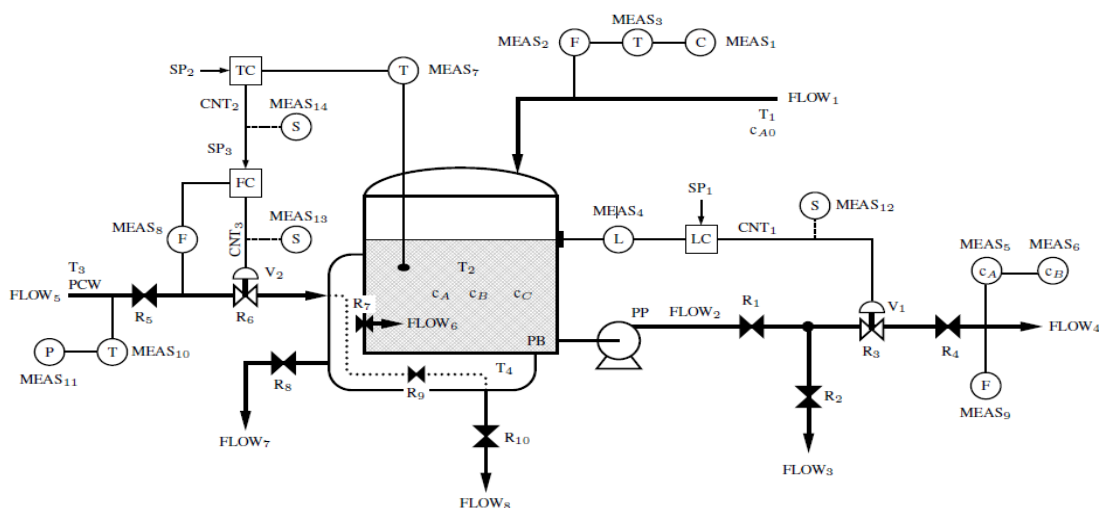
3 ESTUDOS DE CASO

Para ilustrar a eficácia das técnicas apresentadas na seção anterior, faz-se sua aplicação em um processo simulado e um processo real. A primeira aplicação será realizada em um simulador de processo químico, o CSTR (*Continuous Stirred-Tank Reactor* – Reator de Tanque Continuamente Agitado), um reator tanque continuamente agitado, utilizado por diversos autores na literatura, inclusive por Kano et al. (2004), onde são feitos os testes para sua técnica de análise externa. A segunda e a terceira aplicação serão feitas utilizando dados de ventiladores industriais de um processo de pelletização de minério de ferro.

3.1 CSTR

No CSTR ocorre uma reação exotérmica no reator, e o modelo simulado tem como base o presente nos trabalhos de Finch (1989) e Oyelele (1989). A grande motivação no uso desse reator é sua alta não-linearidade, a interação entre suas malhas de controle, os seus múltiplos caminhos causais e pela possibilidade de simular falhas que afetam diferentes conjuntos de variáveis. Na figura 7 é mostrado um esquemático do processo.

Figura 7 – Esquemático do processo CSTR



Fonte: Adaptado de (FINCH, 1989).

3.1.1 Descrição do Processo

Para um dado reagente A de entrada, com concentração c_{A0} , temperatura T_1 e vazão de entrada F_1 , ocorrem duas reações de primeira ordem no reator, $A \rightarrow B$ e $A \rightarrow C$. A

primeira reação é exotérmica e dominante no processo enquanto a segunda reação é endotérmica, fazendo com que o balanço final de energia do reator seja exotérmico, liberando calor e elevando a temperatura do reator para uma determinada temperatura T_2 . Os produtos B, C e o restante do reagente A são bombeados para fora do reator com uma vazão F_2 e concentrações c_A, c_B . Por ser de tamanho considerado desprezível, a concentração de cc é ignorada. Um vazamento com vazão F_3 pode ocorrer durante a retirada dos produtos, tornando então a vazão final de produto do reator a diferença entre F_2 e F_3 , resultando na vazão F_4 . O nível L do tanque é controlado pelo controlador LC, com estrutura PI, mantendo o nível constante em um determinado *setpoint* SP_1 através do sinal de controle CNT_1 para válvula de controle V_1 .

Como a reação é exotérmica, é necessário algum tipo de mecanismo de resfriamento do reator, evitando sobreaquecimentos. Para isso, um fluido com vazão F_5 e temperatura T_3 passa pela jaqueta do reator e sai com uma vazão F_8 . A temperatura dentro da jaqueta é T_4 e é maior que a do líquido refrigerante, T_3 , devido a troca de calor com o reator, resfriando o mesmo. Dois vazamentos podem ocorrer na parte de resfriamento, originando nas vazões F_6 e F_7 . A temperatura do reator é mantida constante devido a um controlador em cascata. O controlador primário tem *setpoint* SP_2 , de temperatura do reator, entregando um sinal de controle CNT_2 como entrada para o controlador subsequente. A vazão que passa pela jaqueta é controlada por esse controlador em cascata através da válvula V_2 , que recebe um sinal de controle CNT_3 . As válvulas foram modeladas como resistências a passagem de líquido no processo, onde a resistência das válvulas é calculada com base no sinal de controle recebido. Para as válvulas do controle de nível e de temperatura a equação (35) representa o cálculo da resistência

$$R = 5e^{0.0545V} \quad (35)$$

onde V é calculado pela equação (36)

$$V = 100 - CNT \quad (36)$$

sendo CNT o sinal de controle enviado pelo controlador a válvula, que é limitado no intervalo $[0; 100]$. O processo possui 16 medidas disponíveis, presentes na tabela 1, e com a possibilidade de serem simuladas 23 tipos diferentes de falhas, presentes na tabela 2.

Tabela 1 – Variáveis do processo CSTR

Número	Variável	Sigla	V. Nominal	Unidade
1	Concentração de entrada	c_{A0}	20.00	mol/m ³
2	Vazão de entrada	F_1	0.25	m ³ /s
3	Temperatura de entrada	T_1	30.00	°C
4	Nível do Reator	L	2.00	m
5	Concentração de Produto A	c_A	2.85	mol/m ³
6	Concentração de Produto B	c_B	17.11	mol/m ³
7	Temperatura do Reator	T_2	80.00	°C
8	Vazão de Refrigerante	F_5	0.90	m ³ /s
9	Vazão de Produto	F_4	0.25	m ³ /s
10	Temperatura Refrigerante	T_3	20.00	°C
11	Pressão Refrigerante	PCW	56250.00	Pa
12	Sinal de Controle Nível	CNT ₁	74.7	-
13	Sinal de Controle de Vazão	CNT ₃	0.9	-
14	Setpoint Controle Vazão	CNT ₂	59.3	-
15	Setpoint Controle Nível	SP ₁	2.00	-
16	Setpoint Controle Temp.	SP ₂	80.00	-

Fonte: Elaborado pelo autor

Tabela 2 – Falhas possíveis no simulador

Número	Falha	Parâmetro Afetado
1	Sem falha	-
2	Bloqueio na saída do reator	R_1
3	Bloqueio na jaqueta de resfriamento	R_9
4	Vazamento da jaqueta para o ambiente	R_8
5	Vazamento da jaqueta para o tanque	R_7
6	Vazamento na bomba	R_2
7	Perda de pressão na bomba	PP
8	Perda de área de contato do reator com a jaqueta	UA
9	Fonte externa de calor	Q_{ext}
10	Energia de ativação da reação primária	β_1

11	Energia de ativação da reação secundária	β_2
12	Vazão de entrada anormal	F_1
13	Temperatura de entrada anormal	T_1
14	Concentração de entrada anormal	c_{A0}
15	Temperatura de resfriamento anormal	T_3
16	Pressão de resfriamento anormal	PCW
17	Pressão do refrigerante na jaqueta anormal	JEP
18	Pressão do produto no reator anormal	REP
19	Offset no setpoint de nível	SP ₁
20	Offset no setpoint de temperature	SP ₂
21	Válvula 1 de controle com agarramento	V ₁
22	Válvula 2 de controle com agarramento	V ₂
23	Falhas em sensores	MEDIDAS

Fonte: Elaborado pelo autor

Alguns dos parâmetros mostrados nas tabelas 1 e 2 não foram citados no texto, sendo necessária uma descrição com um nível maior de detalhes para que elas apareçam na descrição do mesmo. Em Finch (1989) e Oyelele (1989) o simulador é descrito com uma gama maior de detalhes, incluindo descrições relacionadas às equações de troca térmica, equações da reação química entre outros aspectos.

3.2 VENTILADOR INDUSTRIAL

Máquinas que adicionam energia a um fluido, realizando trabalho sobre ele, são denominadas bombas quando o escoamento é de líquido ou pastoso, e ventiladores, sopradores ou compressores para unidades que lidam com gás ou vapor, dependendo do aumento de pressão (FOX, 2000). Para um ventilador, o aumento de pressão geralmente é pequeno, na ordem de 25mm de coluna de mercúrio. Esses equipamentos consistem em um elemento rotativo, geralmente o rotor de um motor elétrico acionado por um drive de potência, para aumentar a energia sobre o fluido que passa por ele. O formato das pás no rotor também pode alterar como a energia é transferida para o fluido, sendo ilustrado na figura 8 ventiladores com pás axiais e radiais.

Tomando como exemplo um processo industrial de pelletização de minério de ferro, um processo de aglomeração de finos de minério, é possível visualizar a importância, tanto para o processo quanto para os custos de produção que um ventilador industrial tem sobre a planta como um todo. Durante a passagem das pelotas pelo forno de pelletização, as pelotas são cozidas pelo fluxo de gases quentes que passam entre elas. Este fluxo de gás é gerado por vários ventiladores de grande porte, da ordem de MW de potência, reaproveitando os gases quentes do processo. Caso ocorra algum defeito em qualquer um dos ventiladores do processo é necessário uma parada total da planta para sua manutenção.





Figura 8 – Ventilador industrial (a) pás axiais e (b) com pás radiais

Devido a criticidade do equipamento para um processo industrial, tal como o de pelletização descrito acima, eles possuem vários instrumentos de proteção, como medidores de temperatura de ar de serviço, pressão de trabalho, vibração dos mancais, potência no eixo, entre outros. O acompanhamento do desempenho de tais equipamentos também pode se dar pelas suas curvas características, disponibilizadas pelo fabricante, onde se pode estimar qual a região de operação que o ventilador está operando. Geralmente, ventiladores possuem duas curvas, uma que relaciona a vazão com a pressão, geralmente a estática ou o total, a curva QF, e outra que relaciona a vazão com a potência no eixo do ventilador, a curva QP. Com isso, tem-se toda informação sobre o comportamento da máquina rotativa. Na figura 9 é ilustrado o comportamento das curvas características de um ventilador para diferentes configurações das pás no rotor

Figura 9 – Curvas Características para diferentes configurações das pás no rotor (a) Centrifugo com pás inclinadas para trás (b) centrifugo com pás inclinadas para frente (c) axial propulsor e (d) tubo axial



Fonte: Disciplina operações unitárias UFPR - <
http://ftp.demec.ufpr.br/disciplinas/TM120/-ventiladores_arquivos-Image201_gif_arquivos/ventiladores.htm >

As curvas fornecidas pelo fabricante ilustram somente o comportamento do ventilador para uma rotação específica. Para que seja possível utilizar as curvas para qualquer rotação do ventilador são aplicadas as regras de semelhança, demonstradas em Fox (2000), que são relações da vazão, pressão e potência com a rotação do ventilador. As regras são expressas pelas equações (37), (38) e (39)

$$\frac{Q_2}{Q_1} = \frac{N_2}{N_1} \quad (37)$$

$$\frac{H_2}{H_1} = \left(\frac{N_2}{N_1}\right)^2 \quad (38)$$

$$\frac{P_2}{P_1} = \left(\frac{N_2}{N_1}\right)^3 \quad (39)$$

onde Q é a vazão, N a rotação, H a pressão e P a potência do ventilador. Com base nas regras, é possível deduzir novos valores de vazão, pressão e potência utilizando como referência a rotação da curva e a rotação a qual se deseja obter o parâmetro. A obtenção das curvas características é feita por ensaios em laboratório pelo fabricante do equipamento, com temperatura de operação constante, ou seja, o ar que passa pelo

ventilador tem densidade constante. No processo do forno de pelotização, por exemplo, os gases que passam pelos ventiladores possuem altas temperaturas, fazendo com que a densidade do mesmo seja diferente da densidade em que foi gerada sua curva característica. A figura 10 ilustra o efeito da alteração da densidade do gás na curva característica do ventilador, onde as curvas pontilhadas e contínuas são para densidades de gás diferentes. Quando se utiliza as curvas de um determinado fabricante, é necessário ajustá-la também a densidade do gás, assim como para rotação. Com isso, a correção da pressão, potência com base na densidade é feita pelas equações (40), (41) e (42)


$$H_c = H \left(\frac{\rho_c}{\rho} \right) \quad (40)$$

$$P_c = P \left(\frac{\rho_c}{\rho} \right) \quad (41)$$

$$Q_c = Q \quad (42)$$

onde ρ_c é a densidade atual do gás e ρ a densidade de referência das curvas características.

Figura 10 - Efeito da densidade sobre as curvas características do ventilador



Fonte: Adaptado de <https://www.nyb.com/pdf/Catalog/Letters/EL-04.pdf>

De posse das curvas características do ventilador e a medição dos sinais de pressão, potência e rotação é possível monitorar a performance do ventilador de duas formas distintas, mas com o mesmo objetivo, o monitoramento do seu desempenho operacional. A primeira forma, e a mais utilizada na literatura, presente em Niinimäki et al. (2013) e Ahonen et al. (2013), é estimar a pressão utilizando a potência no eixo medida pelo drive de acionamento do ventilador. A vazão é estimada com base na curva QP e posteriormente é estimada uma pressão pela curva QF, definindo assim o ponto operacional do equipamento. A segunda forma realiza a comparação entre a potência medida pelo drive de acionamento e a estimada pelas curvas características, presente em Attivissimo et al. (2014), utilizando como base o sinal de pressão para estimar a potência. Um aumento na diferença entre a potência estimada e a medida indica problemas na máquina. Assim, este método pode ser utilizado para detectar uma degradação no comportamento do ventilador, assim como falhas nos sensores utilizados como base para estimação da potência, neste caso o sensor de pressão.

Outros sinais importantes do ventilador também devem ser monitorados, tais como a vibração e temperatura dos seus mancais. Qualquer aumento na vibração pode acelerar a degradação da parte mecânica do equipamento, podendo causar falhas graves que necessitem de paradas da planta industrial. Por operar em diversas regiões de rotação diferentes, para se realizar um monitoramento mais confiável da vibração pode se utilizar a análise externa, considerando que uma variação na rotação implica também em uma variação na vibração dos mancais. Assim, a variável externa será a rotação do ventilador e as variáveis principais a vibração dos mancais, com o resíduo gerado utilizado no monitoramento do equipamento. Resumidamente, as variáveis a serem utilizadas no monitoramento do equipamento nas aplicações estão presentes na tabela 3.

Tabela 3 – Sinais utilizados nas aplicações do ventilador

Número	Variável	Unidade
1	Vibração Lado Acoplado (LA)	mm/s ²
2	Vibração Lado Não Acoplado (LNA)	mm/s ²
3	Temperatura do ar de serviço	°C
4	Rotação	RPM
5	Diferença de Pressão	mmH ₂ O
6	Potência no eixo	kW

Com o CSTR e o comportamento do ventilador devidamente explicados, o próximo passo é a utilização de ambos em aplicações, que validem as técnicas citadas para detecção de falhas.


4 APLICAÇÃO E DISCUSSÃO DOS RESULTADOS

Os estudos de casos mostrados na seção anterior, o simulador CSTR e o ventilador industrial, serão utilizados em aplicações das técnicas citadas na seção 2. A primeira aplicação será feita utilizando as técnicas clássicas de detecção de falhas aliadas a análise externa. A segunda aplicação consiste na utilização de dados de um ventilador industrial para o monitoramento dos seus níveis de vibração. E a terceira aplicação é a utilização das curvas fornecidas pelo fabricante do equipamento para realizar o monitoramento sobre a potência do ventilador.

4.1 APLICAÇÃO AO CSTR

Para aplicação da análise externa no processo, é necessário a divisão das variáveis nos dois conjuntos, das externas e das principais. A influência das mudanças sobre as variáveis externas nas principais será retirada utilizando as equações (24) e (25). Os modelos de análise externa não se limitam a somente modelos lineares, podendo ser utilizados também modelos não lineares para sua aplicação, desde que as variáveis externas escolhidas possuam alguma relação não linear com as variáveis principais. A escolha das variáveis externas passa por aquelas que definem as condições operacionais do processo, no caso variáveis de entrada e *setpoints*. Analisando as variáveis do CSTR e as equações do processo, foi possível separar os dois grupos de variáveis em externa e principais. As variáveis de *setpoint* de nível e temperatura, a vazão, temperatura e concentração de entrada e a pressão e temperatura de líquido refrigerante aparecem como candidatas a variável externa no processo por serem variáveis de entrada nas equações do processo. Foram selecionadas somente os *setpoints* de temperatura e nível como variáveis externas para a aplicação em questão, enquanto que o conjunto de variáveis principais incluem somente aquelas afetadas pelas variáveis externas, excluindo as outras variáveis de entrada. Com a variação do *setpoint* de temperatura, é observada uma relação com características não lineares com as variáveis do sistema de resfriamento. Na figura 11 é utilizada somente uma dessas variáveis, o sinal de controle do controlador de vazão de resfriamento, para ilustrar o comportamento dessa relação.

Figura 11 - Relação entre o *setpoint* de temperatura e o sinal de controle de resfriamento



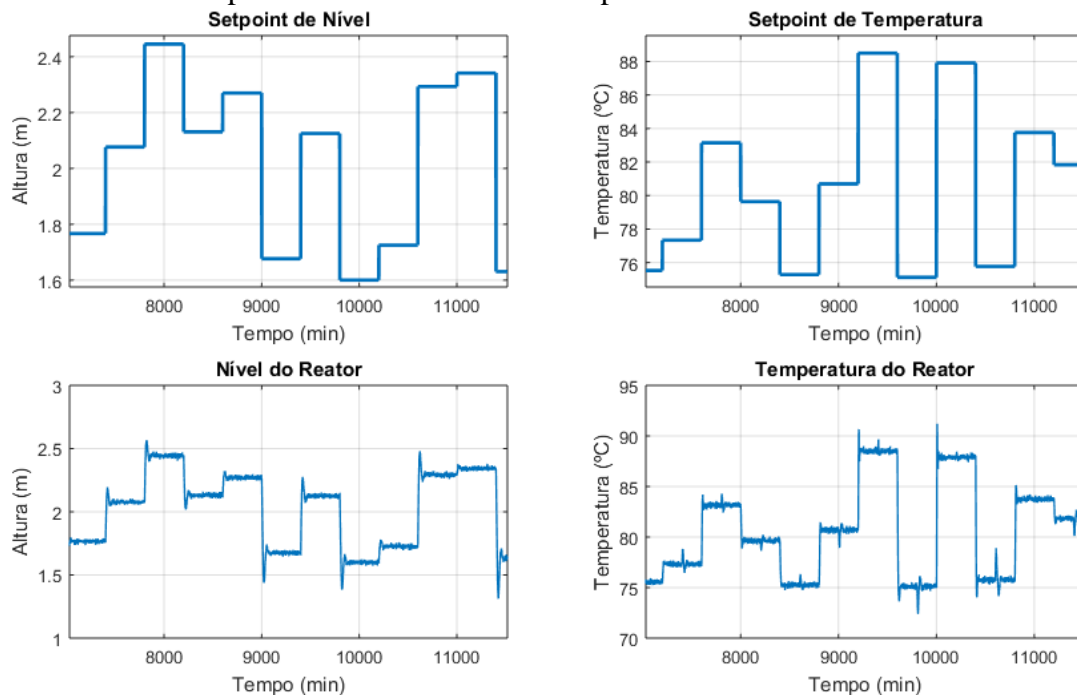
Fonte: Elaborado pelo autor

Por essa relação não linear entre algumas variáveis e a variável do *setpoint* de temperatura, serão utilizados quatro tipos de modelos distintos para esta aplicação. O primeiro modelo consiste em um modelo linear, baseado na regressão por mínimos quadrados convencional e tem a estrutura dada pela equação (31). Pela figura 12, é observado uma dinâmica entre as transições de região de operação, então para isso também será utilizado um modelo dinâmico, que considere os instantes passados, com a mesma estrutura da equação (32). Como algumas variáveis têm características não lineares com relação as variações nos *setpoints* serão utilizados mais dois modelos, um não linear estático e um não linear que considere a dinâmica do processo, e o acréscimo da não linearidade é ilustrada pela equação (33). A quantidade de atrasos selecionados foi utilizando o mesmo princípio de Kano et al. (2004), sendo escolhidos com base na quantidade de amostras presentes no transitório entre as regiões. A estrutura do modelo não linear escolhido foi de um polinômio de segunda ordem.

Antes do processo de detecção, é necessário realizar o treinamento dos modelos. Cada variável externa sofreu quarenta variações aleatórias, na forma de degraus, sendo as de nível no intervalo de $[1.6; 2.5]$ m e as de temperatura no intervalo de $[75; 90]$ °C. As variações de nível e temperatura não são simultâneas, permanecendo em cada região de operação por um intervalo de 200 amostras, gerando um total de 80 regiões de operação distintas. Na figura 12 é ilustrado o comportamento das variáveis externas durante um

trecho da etapa de treinamento e também os respectivos comportamentos do nível e da temperatura do reator. Caso as variações sejam mais suaves que um degrau, como rampas ou variações com comportamento senoidal, fica difícil a visualização da dinâmica do processo, e consequentemente o treinamento de um modelo que consiga representa-la.

Figura 12 - Variações nos *setpoints* de nível e temperatura para treinamento e o comportamento dos sinais de temperatura de nível do reator




Fonte: Elaborado pelo autor

Todos os modelos dinâmicos foram treinados com 30 atrasos. A verificação da qualidade dos modelos treinados é feita pela norma euclidiana, ou norma 2, dos resíduos que eles produzem. A norma euclidiana para um dado vetor x com n observações é calculada pela equação (34).

Quanto menor a norma dos resíduos, maior a quantidade de informação que o modelo consegue representar do conjunto de dados de treinamento. A norma será calculada para cada variável, individualmente, e na figura 13 estão representadas aquelas variáveis que tiveram uma maior alteração na norma com a mudança do modelo linear para o não linear. Para as variáveis ilustradas pela figura 13, existe uma clara relação entre a redução do resíduo e o aumento da complexidade do modelo, seja adicionando atrasos ou fatores não lineares.

Figura 13 - Norma dos resíduos das variáveis 8, 13 e 14 para os diferentes tipos de modelos testados



Fonte: Elaborado pelo autor

A etapa de validação dos modelos para detecção de falhas é o próximo passo. A métrica de comparação para verificar a efetividade dos modelos na detecção de falha é o tempo médio da detecção de uma determinada falha em 100 simulações distintas, posterior a mudança aleatória de região de operação, mas dentro do intervalo para qual os modelos foram treinados. Serão simuladas as falhas 2 a 11, 17 e 18 da tabela 2. As falhas não simuladas correspondem a variações em possíveis variáveis externas, variáveis de entrada do processo, não sendo consideradas falhas pelo conceito de análise externa. O modelo PCA utilizado para detecção da falha é treinado com base nos resíduos das variáveis na etapa de treinamento, com um limiar de 99% de confiança.

Os dados gerados para aplicação do processo de detecção de falhas possuem 800 amostras no total, sendo uma mudança de região após 300 amostras do início da simulação e a falha presente no instante 500, para que a falha não ocorra durante um período de transição entre regiões de operação. Os resultados para o tempo médio de detecção de todas as falhas simuladas estão presentes na tabela 4 e na figura 14 estão


representados os resultados de maior destaque. Não será mostrado a quantidade de falsos positivos de cada modelo para cada falha pois eles estiveram dentro do limiar proposto pelo modelo de detecção de falha.

Tabela 4 – Resultados Simulação de Falhas CSTR

Falha Simulada	Tempo médio de Detecção da Falha (min)			
	Linear estático	Linear dinâmico	Não linear estático	Não linear dinâmico
Falha 2	18.50	6.93	18.72	6.62
Falha 3	9.64	8.79	7.55	6.67
Falha 4	215.33	203.51	185.31	183.81
Falha 5	95.27	87.59	94.03	88.11
Falha 6	106.69	88.23	107.24	85.88
Falha 7	39.31	11.07	39.41	10.57
Falha 8	30.69	24.65	27.72	22.96
Falha 9	38.23	30.49	23.56	18.62
Falha 10	5.63	4.10	4.99	3.69
Falha 11	105.02	71.46	87.39	71.82
Falha 17	34.19	30.04	22.99	19.53
Falha 18	29.55	9.27	29.67	8.89

Fonte: Elaborado pelo autor

Figura 14 - Resultados mais representativos da tabela 4



Fonte: Elaborado pelo autor

Em todas as simulações foi possível realizar a detecção das falhas simuladas no processo. Os resultados mostram que, no geral, uma melhor performance foi obtida utilizando o modelo não linear dinâmico, obtendo um tempo menor que os modelos lineares em todas as falhas simuladas. As maiores diferenças entre os tempos de detecção entre os modelos lineares e os não lineares podem ser vistas justamente nas falhas que mais afetam o sistema de refrigeração, as falhas 4, 9, 11 e 17, presentes na figura 14. Essas falhas causam variações no sistema de refrigeração, tornando mais evidente a relação não linear com a temperatura. Com isso, o modelo não linear estático tem um melhor desempenho na detecção de falha do que o modelo linear com dinâmica. Outro fato observado pelos resultados é quanto o acréscimo da dinâmica nos modelos faz com que ele se torne mais efetivo para detecção de falhas, já que ele contempla também a dinâmica do processo.

Os resultados no simulador foram satisfatórios, já que foi possível a detecção de falha em múltiplas regiões de operação utilizando os modelos de análise externa. Um próximo passo é a aplicação do conceito utilizado para detecção de falhas no simulador em um sistema real, que no presente caso será um ventilador industrial.


4.2 MONITORAMENTO DA VIBRAÇÃO DE UM VENTILADOR INDUSTRIAL

No capítulo 3 foi mostrado como é o funcionamento de um ventilador industrial e sua importância para o bom funcionamento de um processo industrial. O seu monitoramento deve ser realizado por causa da sua criticidade para o processo e por que qualquer falha neste equipamento gera paradas indesejadas da planta. Os ventiladores de grande porte são acionados por motores e sustentados por mancais, normalmente, lubrificados a óleo. O ventilador possui vários instrumentos de proteção e entre os mais importantes estão os medidores de vibração dos mancais. Esses instrumentos podem indicar falhas críticas tais como o desbalanceamento do ventilador, que pode destruir os mancais e danificar a fundação do equipamento.

A aplicação aqui presente busca realizar a detecção de falha de vibração no ventilador, sendo esta detectável pelos sensores de vibração. Devido a esta falha no equipamento, ocorreu uma parada de um número elevado de horas do processo. Para verificar se é possível detectar a falha com antecedência, serão utilizados os sinais de rotação do ventilador, vibração do lado acoplado e vibração do lado não acoplado ao rotor. Neste caso, a variável externa responsável sobre a condição operacional será a


rotação do ventilador, por ela ter influência direta nos níveis de vibração. A figura 15 indica o comportamento da rotação durante o período selecionado, enquanto a figura 16 indica o comportamento de ambas as vibrações no mesmo período.

Figura 15 - Sinal de rotação do ventilador para o período estudado



Fonte: Elaborado pelo autor

Figura 16 - Sinais de vibração do ventilador para o período estudado




Fonte: Elaborado pelo autor

A relação entre os sinais de vibração e o de rotação pode ser vista no momento em que ocorre uma maior variação da rotação, com o mesmo comportamento sendo refletido na vibração do ventilador.

Por termos uma base de dados limitada, o treinamento do modelo tem de ser feito de maneira diferente da aplicação do simulador CSTR. Foram selecionados cinco conjuntos de dados para fazer o treinamento dos modelos, ilustrados na figura 17, e feito um procedimento semelhante a validação cruzada por *k-fold* utilizando cinco *folds*, onde um conjunto é separado para validação e os outros para treinamento, todos sem a presença de falhas. O treinamento termina no momento em que todos os conjuntos foram utilizados para validação e para treino. Nesta aplicação além do modelo linear, estrutura da equação (31), serão utilizados modelos não lineares, entre eles o polinomial de segunda e terceira ordem, com estruturas da equação (33) e da rede neural GRNN.

Figura 17 - Seleção de dados para treinamento



Fonte: Elaborada pelo autor

Um ponto a ser analisado antes da seleção de qual modelo será utilizado na aplicação é a verificação se todos os *folds* correspondem a trechos em que as relações entre a rotação e a vibração se mantêm. Para isso, foram medidos as médias e os desvios padrões dos resíduos de cada modelo treinado, presentes nas tabelas 5 e 6.

Tabela 5 – Média e desvio padrão para a vibração do lado acoplado

	Linear		Polinomial 2° ordem		Polinomial 3° ordem		GRNN	
	Média	Desvio	Média	Desvio	Média	Desvio	Média	Desvio
Fold 1	-0,286	0,175	-0,204	0,146	-0,112	0,121	-0,079	0,143
Fold 2	0,225	0,168	0,17	0,201	0,118	0,118	0,102	0,1245
Fold 3	0,188	0,185	0,072	0,157	0,057	0,105	0,054	0,092
Fold 4	0,149	0,175	0,094	0,159	0,05	0,102	0,037	0,102
Fold 5	0,02	0,16	-0,016	0,137	-0,053	0,114	-0,059	0,111

Fonte: Elaborado pelo autor


Tabela 6 – Média e desvio padrão para a vibração do lado não acoplado

	Linear		Polinomial 2° ordem		Polinomial 3° ordem		GRNN	
	Média	Desvio	Média	Desvio	Média	Desvio	Média	Desvio
Fold 1	-0,323	0,163	-0,291	0,147	-0,213	0,097	-0,19	0,081
Fold 2	0,184	0,151	0,14	0,182	0,094	0,101	0,08	0,103
Fold 3	0,151	0,146	0,057	0,127	0,044	0,082	0,045	0,073
Fold 4	0,322	0,118	0,278	0,161	0,237	0,098	0,212	0,084
Fold 5	0,168	0,147	0,139	0,158	0,105	0,101	0,105	0,084

Fonte: Elaborado pelo autor

Para as duas vibrações não há uma alteração da relação entre a rotação e a vibração, quando se altera os conjuntos de treinamento e validação, pois não há grandes alterações na média e no desvio padrão dos resíduos quando se considera a magnitude da variável de vibração. A norma dos resíduos para cada modelo treinado foi calculada e está presente na figura 18. No *fold 5* os modelos obtiveram um melhor resultado geral em relação à magnitude da norma do resíduo. Neste *fold* o conjunto em azul da figura 17 foi utilizado para validação, enquanto os outros são utilizados para o treinamento do modelo. Os resíduos do treinamento deste modelo foram utilizados para construção do modelo PCA que será utilizado para detecção de falhas, com um limiar de 99% de confiança.

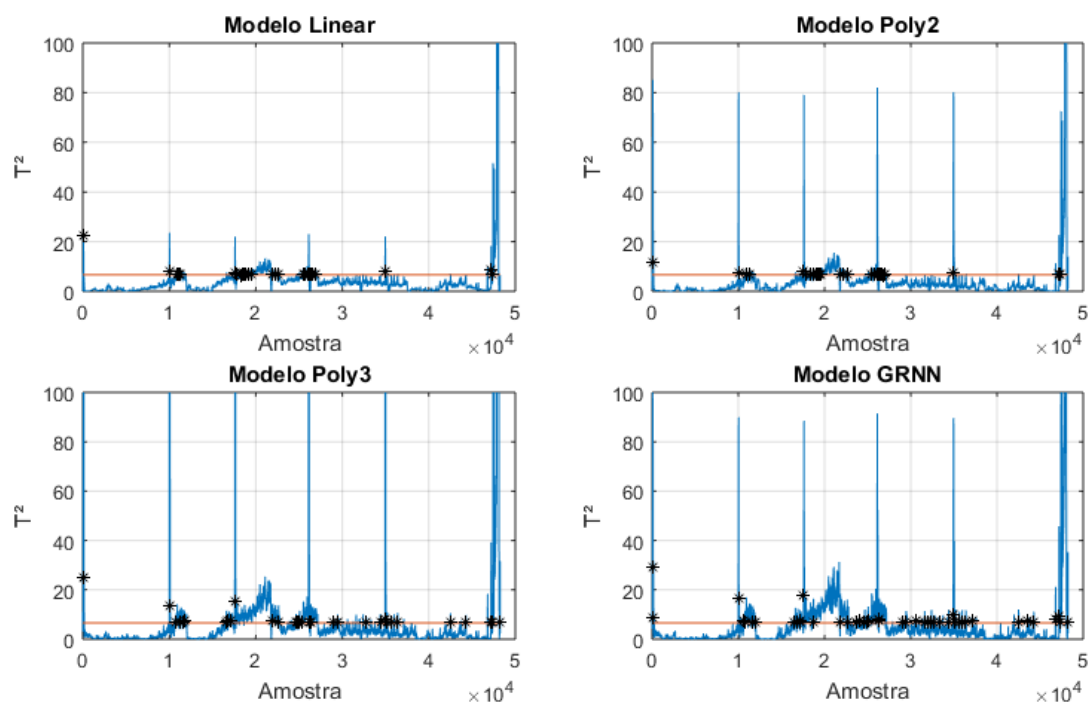
Figura 18 - Normas dos resíduos de cada modelo em cada etapa do treinamento



Fonte: Elaborado pelo autor

Algumas métricas serão medidas para verificar a qualidade do modelo em relação a detecção de falhas: os falsos positivos, tempo de detecção das falhas e a norma dos resíduos. Observando os dados das figuras 15 e 16, são observados dois momentos em que o comportamento da vibração pode ser considerado anormal. O primeiro intervalo é entre as horas 40 e 60, em que há uma elevação da vibração sem mudanças na rotação, e o segundo intervalo, uma falha mais crítica, em que há uma elevação grande da vibração posterior ao instante de 130h, quando ocorre a parada do equipamento. Na figura 19 são mostrados os resultados da aplicação dos modelos PCA de cada modelo para todo o conjunto de dados e a figura 20 e a tabela 7 trazem as métricas calculadas para cada modelo.

Figura 19 - Estatísticas de monitoramento para cada modelo de análise externa



Fonte: Elaborado pelo autor

Pela figura 19, é visto que os modelos menos complexos utilizados, o linear e o polinomial de segunda ordem, são os menos sensíveis em relação a ocorrência de variações na vibração durante o primeiro momento de falha. Este fato é visível pela amplitude da estatística durante o momento em questão. Para o segundo momento, por ser uma falha mais crítica, todos os modelos detectaram a falha com clareza, com a estatística desviando com rapidez do limiar proposto.

As métricas selecionadas para medição da qualidade dos modelos foram os falsos positivos, que são indicações de falha na estatística durante períodos de normalidade, o tempo de detecção de ambas as falhas em relação ao modelo que detectou a falha com maior rapidez e a norma dos resíduos, que são medidos durante a etapa de treinamento, sendo quanto menor o valor dos resíduos, maior a adequação do modelo aos dados de treinamento. Todos os resultados referentes as métricas estão presentes na tabela 6, para cada modelo treinado.

Tabela 7 – Métricas medidas na aplicação

Modelo	Falsos Positivos	Tempo de Detecção – Falha 1	Tempo de Detecção – Falha 2	Norma dos resíduos
Linear	1.71%	5.56h	0.033h	12.49
Polinomial 2ª Ordem	1.37%	5.55h	0.033h	11.37
Polinomial 3ª Ordem	5.61%	0h	0.017h	7.44
GRNN	6.31%	0h	0h	6.70

Fonte: Elaborado pelo autor

Os resultados indicam que um modelo mais complexo realiza uma detecção de falha mais rápida, principalmente para quando a falha tem uma evolução mais lenta. Neste caso, a detecção de falha ocorreu com mais de 5h de antecedência em comparação que os modelos lineares e polinomial de segunda ordem. Considerando somente os falsos positivos, calculados com os dados de treinamento, iria-se indicar, erroneamente, os modelos mais simples como aqueles com melhor desempenho. A baixa taxa de falsos positivos, por si só, não é um bom indicativo da qualidade do modelo, como pode ser visto pela norma dos resíduos daqueles que obtiveram a menor taxa de falsos positivos. A norma dos resíduos é um modo de verificar o quão longe está o estimado do real, sendo assim quando menor a norma dos resíduos, melhor o resultado. A utilização de um modelo linear para este caso não seria ideal, devido a relação entre a rotação e a vibração terem características não lineares fortes. Assim, um modelo não linear consegue representar melhor as mudanças e gerar resíduos melhores para detecção de falhas do processo em questão, fazendo com que o modelo utilizado para detecção de falhas aceite mais variações do que o modelo PCA treinado com os resíduos dos modelos mais complexos.

A utilização da análise externa para o monitoramento de detecção de anomalias na vibração conseguiu obter bons resultados, detectando a falha, no primeiro momento, antes que ela se tornasse crítica demais e forçasse uma parada do equipamento para manutenção ou até mesmo que a falha causasse um dano crítico ao equipamento, forçando a sua substituição.

A seleção de dados de treinamento é um fator que diferencia e dificulta a aplicação em um processo real. Em um ambiente simulado, como o CSTR, é possível alterar os parâmetros e construir o conjunto de dados que ajudem a fazer uma modelagem adequada do processo. No ventilador industrial, a base de dados é limitada, existindo uma maior dificuldade em obter dados que representem o comportamento do equipamento e a relação entre as variáveis a serem utilizadas no monitoramento. Caso não ocorra nenhuma variação, a utilização dos dados para construir um modelo se torna inviável, e o modelo não vai corresponder ao comportamento real do equipamento.

4.3 APLICAÇÃO PARA O MONITORAMENTO DE EFICIÊNCIA DO VENTILADOR


Outro método que pode ser utilizado para monitoramento de ventiladores é através da utilização das suas curvas características para detecção de degradação de eficiência ou falhas nas medições de pressão ou potência, comparando o estimado pelas curvas com os medidos no processo, como foi mencionado na seção 3.2 que é possível realizar. A aplicação então, consiste na utilização dos modelos propostos, que consigam representar o equipamento nas suas diversas condições operacionais, pelo fabricante para geração de resíduos do sinal de potência para monitorar o comportamento do equipamento.

Para a aplicação aqui presente, serão utilizados dados reais de um ventilador industrial presente em uma planta de pelletização e também as curvas características desse equipamento, que são fornecidos pelo fabricante, presente na figura 20 para o ventilador utilizado na aplicação. A base de dados para trabalho inclui dados dos meses de agosto, setembro, outubro, novembro e dezembro.

O primeiro passo é a aquisição dos dados referentes as curvas características de pressão e potência do ventilador e sua representação em ambiente computacional. Com esses dados, é possível calcular modelos, curvas, que melhor se adequem ao comportamento deles. Os dados da figura 20 foram retirados e utilizados no cálculo de modelos, presentes na figura 21. Pode ser visto, na figura 21, que há uma sobreposição entre a curva original, em vermelho, e a curva do modelo calculada, em azul, tanto para as curvas de pressão, quanto para as de potência. Só existe três curvas relativas ao comportamento da máquina, sendo cada curva para uma rotação específica. Essa limitação pode ser superada utilizando as leis de semelhança para bombas e ventiladores, presentes nas equações (37), (38), e (39). Essas leis, como é mencionado na seção 3.2,


tornam possível encontrar as curvas características da máquina rotativa para qualquer nível de rotação.

Figura 20 - Curvas características do ventilador



Fonte: Elaborado pelo autor

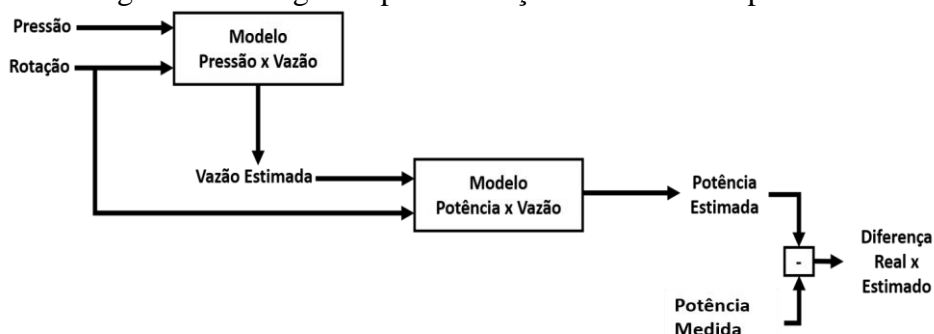
Figura 21 - Curvas características em ambiente computacional



Fonte: Elaborado pelo autor

Quanto mais distante está a rotação em que se quer calcular a curva e a que se tem fornecida pelo fabricante, aumenta o erro de previsão do comportamento do ventilador, sendo esse fato ilustrados em (AHONEM et al. 2011). Por esse motivo, o plano de ambas as curvas foi dividido em três seções, em que cada curva fornecida pelo fabricante será utilizada como referência em uma determinada região. Com os modelos construídos, o diagrama da sequência da aplicação é ilustrado pela figura 22, onde são mostrados os passos necessários para obtenção do resíduo da diferença entre as potências.


Figura 22 – Diagrama para obtenção do resíduo de potência



Fonte: Elaborado pelo autor

A figura 23 traz a potência estimada pelo diagrama proposto na figura 22. Foram utilizados dados correspondentes a 576 horas de operação, para verificar se é possível estimar a potência somente pelas curvas fornecidas pelo fabricante.

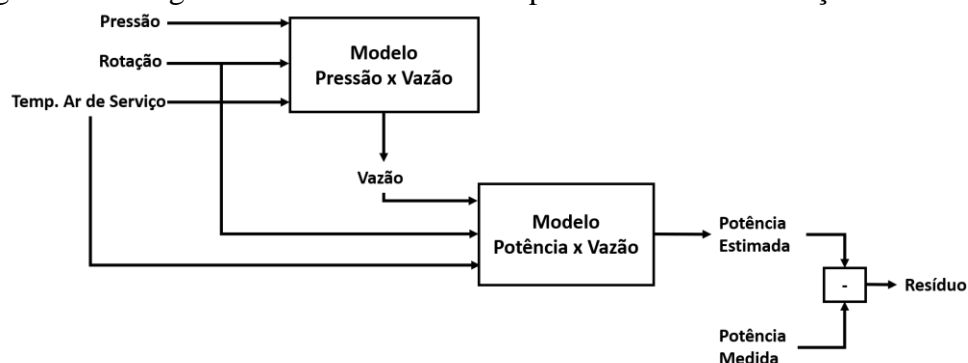
Figura 23 – Sinal de potência medido, estimado e o resíduo resultante



Fonte: Elaborado pelo autor.

Utilizando somente o sinal de rotação e pressão para estimação de potência ainda gera grandes resíduos, não representando adequadamente o comportamento do ventilador. Para que a estimação seja realmente efetiva, é necessário também corrigir os sinais de pressão e potência nas curvas pela densidade de operação do ventilador, como é demonstrado na seção 3.2. A densidade é diretamente proporcional a temperatura de ar de serviço do ventilador, fazendo com que o sinal de temperatura tenha uma grande importância para estimação correta da potência do ventilador. Realizando as devidas correções nas curvas de desempenho do ventilador, com base na densidade do ar de operação, a figura 24 ilustra o novo diagrama, para obtenção do resíduo da potência que será monitorado.


Figura 24 – Diagrama atualizado com a temperatura do ar de serviço do ventilador



Fonte: Elaborado pelo autor

Utilizando as correções devidas sobre as curvas de pressão e potência, a figura 25 retrata a potência estimada depois das correções.

Figura 25 – Potência estimada corrigida com a densidade




Fonte: Elaborado pelo autor

Para verificar o desempenho do ventilador será analisado somente o sinal do resíduo entre as potências, tornando-se uma análise univariada de um único sinal. Considerando a distribuição do sinal como aproximadamente normal, um limiar de controle será realizado, para que quando o sinal monitorado sair espaço entre os limiares, algum comportamento não previsto pelo modelo ocorreu no processo. O limiar terá 99% de confiança e serão utilizados os dados até as 192 horas de processo, conforme a figura 25, para sua construção. A construção do limiar será feita utilizando um *k-fold* com cinco dobras, ou seja, dividindo o conjunto de treinamento em cinco, aleatoriamente, e cada vez será utilizado um conjunto para construção do limiar. O limiar a ser utilizado é aquele

que alcançou a menor taxa de falsos positivos dentre os cinco limiares testados. Assim, a figura 26 ilustra o limiar, que teve uma taxa de 8091 falsos positivos para 928000 amostras, o que dá uma taxa de somente de 0.87%, bem próxima do limite de 1% estabelecido pelo limiar.


Figura 26 - Resíduo da potência com os limiares de controle



Fonte: Elaborado pelo autor

Observando a figura 26, é observado um momento em que ocorre uma subida no sinal monitorado, entre 270h e 400h, onde o sinal está margeando o limiar de controle, sendo um indicativo de alguma alteração no comportamento dos sinais medidos, mesmo que leve. A figura 27 traz os sinais de rotação e diferença de pressão no equipamento para os mesmos instantes mostrados na figura 26. Neste mesmo momento, da elevação no sinal monitorado, a rotação mantém seu comportamento em comparação ao mesmo momento no qual foi construído o limiar, enquanto no sinal de diferença de pressão ocorre uma alteração no sinal, o que leva a alteração da estimacão da potência. Por ser um comportamento não desejado, um aumento súbito em algum sinal medido, a carta univariada deve indicar este momento, com amostras suficientes ultrapassando o limiar.


Figura 27 - Sinais de rotação e diferença de pressão



Fonte: Elaborado pelo autor

O mesmo trecho que foi utilizado para construção do limiar estatístico univariado, foi utilizado também para construção de um modelo PCA utilizando as variáveis de rotação, diferença de pressão e temperatura do ar serviço do ventilador. A estatística indicará falha sempre que uma das variáveis romper com a correlação presente no modelo PCA. Na figura 28 é ilustrada a estatística T^2 para o mesmo conjunto de dados aqui analisado na figura 27. No mesmo trecho em que a variável de diferença de pressão tem uma alteração de comportamento, a estatística indica que houve uma quebra na correlação entre as variáveis, desviando do limiar proposto, de 99% de confiança.


Figura 28 - Estatística T^2 para as variáveis de rotação, diferença de pressão e temperatura do ar de serviço do ventilador



Fonte: Elaborado pelo autor

Um novo teste foi feito com dados referentes ao mês de janeiro do ano de 2018. A intenção do novo teste é verificar se o ventilador mantém o seu comportamento para um período diferente de tempo. A potência para esse novo período foi estimada e os resíduos calculados. Na figura 29 estes dados são ilustrados, assim como os limiares univariados calculados anteriormente. O comportamento do resíduo nesse período está próximo de violar o limiar definitivamente, indicando uma alteração no comportamento do resíduo em relação ao resíduo que foi utilizado no treinamento do limiar. Um resíduo negativo indica que a potência estimada está maior que a real, ou seja, o ventilador está gastando menos energia para gerar a mesma diferença de pressão que o previsto pelo modelo. Para essa situação, tem que se atentar em dois pontos: a alteração no comportamento pode ser proveniente de falhar nos sensores e que este pode ser o novo comportamento e nível de resíduo normais do processo. Pelo longo tempo em que o resíduo se mantém com o mesmo comportamento, o segundo ponto se torna mais plausível que o primeiro, sendo necessário então um retreinamento dos limiares de controle.

Figura 29 – Potência estimada e resíduos para dados de Jan/18



Fonte: Elaborado pelo autor

5 CONCLUSÃO

A utilização somente de métodos convencionais para detecção de falhas, tais como PCA ou PLS, não tem muita efetividade quando utilizados para detectar falhas em processos que operem em múltiplos modos de operação. Para que o monitoramento seja feito com eficácia foi necessária a utilização de técnicas que tratam essa questão, sendo a análise externa escolhida para aplicação no presente trabalho.

A análise externa foi aplicada em dois estudos de caso, um primeiro utilizando um simulador de processo químico e uma segunda em que se utilizou dados industriais reais de um ventilador de processo na presença de falhas. No primeiro caso várias falhas distintas foram simuladas e verificada a eficácia da detecção de falha do método proposto, a utilização do PCA somente nos resíduos gerados pela análise externa, conseguindo realizar a detecção em todas as falhas simuladas. Um fato observado foi que com o aumento da complexidade do modelo, acrescentado atrasos ou fatores não lineares, fez com que ocorresse uma detecção com maior antecipação, conseguindo representar melhor a relação da variável externa com as principais. No segundo estudo de caso foi aplicado a mesma metodologia do primeiro, e testadas diferentes complexidades do modelo de análise externa. Pelos resultados também foi possível notar que um aumento na complexidade do modelo ocasionou em uma detecção antecipada da falha em relação aos modelos mais simples, tais como modelos lineares.

A relação do terceiro estudo de caso com os dois anteriores é que também são utilizados os resíduos para detecção de falhas. Enquanto os modelos anteriores são construídos utilizando dados históricos dos processos, o modelo do terceiro estudo de caso foi utilizado com base nas curvas do fabricante sobre o equipamento, representado as diversas condições operacionais do equipamento. Foi modelado o comportamento de um ventilador de processo, diferente do utilizado no segundo estudo de caso, para prever a potência esperada de acordo com as curvas do fabricante. O resíduo monitorado foi da diferença entre a potência medida e a estimada, podendo assim verificar se há uma degradação no desempenho do equipamento ou falhas nos sensores envolvidos, tais como de pressão. No estudo de caso presente neste trabalho, foi possível verificar uma alteração nos sensores de pressão que teve reflexo na estimativa de potência no primeiro teste. O segundo teste foi realizado com outro conjunto de dados e por ele foi possível verificar

casos em que o retreinamento do limiar é necessário, caso o processo altere seu comportamento, considerado normal, por um tempo considerado longo.

Conclui-se então que as técnicas utilizadas para representar o processo nas suas diversas condições operacionais, a análise externa e os modelos que representem o processo, foram utilizados com efetividade na detecção de falhas em processo que operam em várias regiões de operação.

REFERÊNCIAS BIBLIOGRÁFICAS

- AHONEN, Tero et al. Accuracy study of frequency converter estimates used in the sensorless diagnostics of induction-motor-driven systems. In: **Power Electronics and Applications (EPE 2011), Proceedings of the 2011-14th European Conference on.** IEEE, 2011. p. 1-10.
- AHONEN, Tero et al. Sensorless estimation of the pumping process characteristics by a frequency converter. In: **Power Electronics and Applications (EPE), 2013 15th European Conference on.** IEEE, 2013. p. 1-10.
- ALCALA, Carlos F.; QIN, S. Joe. Reconstruction-based contribution for process monitoring. **Automatica**, v. 45, n. 7, p. 1593-1600, 2009.
- ATTIVISSIMO, Filippo et al. Model based control and diagnostic system for centrifugal pumps. In: **Environmental Energy and Structural Monitoring Systems (EESMS), 2014 IEEE Workshop on.** IEEE, 2014. p. 1-6.
- ALDRICH, Chris; AURET, Lidia. **Unsupervised process monitoring and fault diagnosis with machine learning methods.** Springer, 2016.
- CHIANG, Leo H.; RUSSELL, Evan L.; BRAATZ, Richard D. **Fault detection and diagnosis in industrial systems.** Springer Science & Business Media, 2000.
- FINCH, Francis Eric. **Automated fault diagnosis of chemical process plants using model-based reasoning.** 1989. Tese de Doutorado. Massachusetts Institute of Technology.
- FOX, Robert W.; PRITCHARD, Philip J.; MCDONALD, Alan T. **Introdução À Mecânica Dos Fluidos.** Grupo Gen-LTC, 2000.
- GE, Zhiqiang; SONG, Zhihuan. **Multivariate statistical process control: Process monitoring methods and applications.** Springer Science & Business Media, 2012.
- GE, Zhiqiang et al. Robust online monitoring for multimode processes based on nonlinear external analysis. **Industrial & Engineering Chemistry Research**, v. 47, n. 14, p. 4775-4783, 2008.
- HOTELLING, Harold. Multivariate quality control. **Techniques of statistical analysis**, 1947.
- HYVÄRINEN, Aapo; OJA, Erkki. Independent component analysis: algorithms and applications. **Neural networks**, v. 13, n. 4-5, p. 411-430, 2000.
- ISERMANN, Rolf. Model-based fault-detection and diagnosis—status and applications. **Annual Reviews in control**, v. 29, n. 1, p. 71-85, 2005.
- JOE QIN, S. Statistical process monitoring: basics and beyond. **Journal of chemometrics**, v. 17, n. 8-9, p. 480-502, 2003.

KANO, Manabu et al. A new multivariate statistical process monitoring method using principal component analysis. **Computers & chemical engineering**, v. 25, n. 7-8, p. 1103-1113, 2001.

KANO, Manabu et al. Evolution of multivariate statistical process control: application of independent component analysis and external analysis. **Computers & chemical engineering**, v. 28, n. 6-7, p. 1157-1166, 2004.

KOURTI, Theodora; MACGREGOR, John F. Process analysis, monitoring and diagnosis, using multivariate projection methods. **Chemometrics and intelligent laboratory systems**, v. 28, n. 1, p. 3-21, 1995.

KOURTI, Theodora. Process analysis and abnormal situation detection: from theory to practice. **IEEE control systems**, v. 22, n. 5, p. 10-25, 2002.

LI, Weihua et al. Recursive PCA for adaptive process monitoring. **Journal of process control**, v. 10, n. 5, p. 471-486, 2000.

MONTGOMERY, Douglas C. **Statistical quality control**. New York: Wiley, 2009.

NIINIMÄKI, Lauri et al. Study of the sensorless operating point estimation for turbocompressors. In: **Power Electronics and Applications (EPE), 2013 15th European Conference on**. IEEE, 2013. p. 1-10.

OYELEYE, Olayiwola Oluwemimo. **Qualitative modeling of continuous chemical processes and applications to fault diagnosis**. 1989. Tese de Doutorado. Massachusetts Institute of Technology.

PAGE, Ewan S. Continuous inspection schemes. **Biometrika**, v. 41, n. 1/2, p. 100-115, 1954.

PEARSON, Karl. Principal components analysis. **The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science**, v. 6, n. 2, p. 559, 1901.

ROBERTS, S. W. Control chart tests based on geometric moving averages. **Technometrics**, v. 1, n. 3, p. 239-250, 1959.

SPECHT, Donald F. A general regression neural network. **IEEE transactions on neural networks**, v. 2, n. 6, p. 568-576, 1991.

VENKATASUBRAMANIAN, Venkat et al. A review of process fault detection and diagnosis: Part III: Process history based methods. **Computers & chemical engineering**, v. 27, n. 3, p. 327-346, 2003.

YOON, Seongkyu; MACGREGOR, John F. Fault diagnosis with multivariate statistical models part I: using steady state fault signatures. **Journal of process control**, v. 11, n. 4, p. 387-400, 2001.

YUE, H. Henry; QIN, S. Joe. Reconstruction-based fault identification using a combined index. **Industrial & engineering chemistry research**, v. 40, n. 20, p. 4403-4414, 2001.

ZHANG, Haitao. **Statistical process monitoring and modeling using PCA and PLS**. 2000. Tese de Mestrado. University of Alberta

ZHANG, Yingwei; WANG, Chuang; LU, Renquan. Modeling and monitoring of multimode process based on subspace separation. **Chemical Engineering Research and Design**, v. 91, n. 5, p. 831-842, 2013.

ZHAO, Shi Jian; ZHANG, Jie; XU, Yong Mao. Monitoring of processes with multiple operating modes through multiple principle component analysis models. **Industrial & engineering chemistry research**, v. 43, n. 22, p. 7025-7035, 2004.

ZHENG, Ying; QIN, S. Joe; CHAI, Tianyou. Fault detection of multimode processes using concurrent projection to latent structures. **IFAC-PapersOnLine**, v. 49, n. 7, p. 705-710, 2016.

ZUQUI, Gercilio C. et al. Robust fault detection and diagnosis for multimode processes. In: **Industry Applications (INDUSCON), 2016 12th IEEE International Conference on**. IEEE, 2016. p. 1-6.